



Urbane Multiobjektverfolgung im Kontext hybrider Umfeldmodelle

Von der Fakultät für Elektrotechnik, Informationstechnik, Physik
der Technischen Universität Carolo-Wilhelmina zu Braunschweig

zur Erlangung der Würde

eines Doktor-Ingenieurs (Dr.-Ing.)

genehmigte Dissertation

von

Helgo Dyckmanns

aus Schwerte

eingereicht am:	3. Mai 2013
mündlichen Prüfung am:	9. Januar 2014
Referenten:	Prof. Dr.-Ing. Maurer Prof. Dr.-Ing. Stiller

2014

Danksagung

Professor Dr.-Ing. Markus Maurer danke ich für die wissenschaftliche Betreuung meiner Arbeit. Des Weiteren danke ich Professor Dr.-Ing. Christoph Stiller für die Übernahme der Berichterstattung und Professor Dr.-Ing. Jörg Schöbel für die Übernahme des Prüfungsvorsitzes.

Richard Matthaei möchte ich für die intensiven wissenschaftlichen Diskussionen danken. Besonderer Dank gilt Dr.-Ing. Bernd Lichte der mich seit der Diplomarbeit und während des Promotionsvorhabens als Mentor fachlich und persönlich unterstützt hat. Richard Colmorn danke ich für die intensiven Diskussionen insbesondere zu Strukturierung und Darstellung meiner Arbeit.

Norbert Höver, Martin Mühlenberg und Brigitte Krause danke ich für die organisatorische Unterstützung bei der Durchführung meines Promotionsvorhabens.

Helgo Dyckmanns

Inhaltsverzeichnis

Danksagung	III
Symbolverzeichnis	VIII
Kurzfassung	X
Abstract	XI
1 Einleitung	1
1.1 Motivation	1
1.2 Herausforderungen für die objektbasierte maschinelle Umfeldwahrnehmung in urbaner Umgebung	3
1.3 Technische Ziele der objektbasierten maschinellen Umfeldwahrnehmung in urbaner Umgebung	4
1.4 Ziele und Gliederung der Arbeit	5
2 Stand der Forschung und Stand der Technik	7
2.1 Allgemeine Forschungsaktivitäten: Aktive Sicherheitssysteme im urbanen Umfeld	7
2.1.1 Europäische Forschungsaktivitäten	8
2.1.2 Japanische Forschungsaktivitäten	10
2.1.3 Deutsche Forschungsaktivitäten	11
2.1.4 Trends in den Forschungsaktivitäten und abgeleitetes Fazit	12
2.2 Wahrnehmungs-Grundlagen und Filter-Verfahren	12
2.2.1 Begrifflichkeiten	13
2.2.2 Laserscanner	16
2.2.3 Partikelfilter	20
2.2.4 Kalman-Filter	21
2.2.5 Interacting-Multi-Model-Filter zur Multiobjektverfolgung	27
2.3 Stand der Technik: Maschinelle Umfeldwahrnehmung in urbaner Umgebung	30
2.3.1 Erweiterungen des Interacting-Multi-Model-Filters (IMM)	30
2.3.2 Hybride Umfeldmodelle: Fusion von objekt- und gitterbasierter Darstellung	33
2.3.3 Verwendung von digitalem Kartenmaterial zur Verbesserung des Szenenverständnisses	38
2.3.4 Güte- und Konsistenzkriterien zur Bewertung des Objekttrackings	41
2.3.5 Grenzen des Stands der Technik und der abgeleitete Forschungsbedarf	42
2.4 Technische Zielsetzung und Randbedingungen dieser Arbeit	43

3	Entwicklungsmethodik und Gütekriterien	45
3.1	Begriffsdefinition	45
3.2	Entwicklungsmethodik	47
3.3	Gütekriterien zur Bewertung von Algorithmen zur Objektverfolgung	48
3.3.1	Abgeleitete Anforderungen an die Bewertung	48
3.3.2	Ansätze aus der Steuerungs- und Regelungstechnik	49
3.3.3	Erweiterte Gütekriterien zur Bewertung der Zustandsunsicherheit im urbanen Umfeld	51
3.4	Diskussion der Entwicklungsmethodik und Gütekriterien	52
4	Technischer Lösungsansatz: Urbanes Objekttracking im Kontext hybrider Umfeldmodelle	54
4.1	Verwendetes hybrides Umfeldmodell	55
4.1.1	Bewegungsklassifikation	56
4.1.2	Gitterbasiertes Umfeldmodell	56
4.1.3	Objektbasiertes Umfeldmodell	58
4.1.4	Graphenbasiertes Umfeldmodell	60
4.2	Messmodell und daraus abgeleitetes Objektmodell	61
4.2.1	Technische Anforderungen	61
4.2.2	Messmodell	62
4.2.3	Objektmodell	66
4.2.4	Zustandsvektor	68
4.2.5	Sensormodell	71
4.2.6	Zusätzliche Design-Parameter des Interacting-Multi-Model-Filters	73
4.2.7	Dynamikmodelle	73
4.2.8	Nachträgliche Konturschätzung	78
4.2.9	Objekthypotheseninitialisierung	81
4.2.10	Fazit	82
4.3	Fusion von objekt- und gitterbasierten Darstellungsformen	83
4.3.1	Problembeschreibung und abgeleitete Anforderungen	83
4.3.2	Lösungsansatz	84
4.3.3	Diskussion	85
4.4	Fusion von objekt- und graphenbasierten Darstellungsformen	87
4.4.1	Problembeschreibung und abgeleitete Anforderungen	87
4.4.2	Lösungsansatz	87
4.4.3	Diskussion	95
4.5	Fazit	98

5	Experimentelle Validierung des technischen Lösungsansatzes	101
5.1	Versuchsaufbau und -technik	101
5.2	Evaluierung des Objekttracking-Systemes	103
5.2.1	Positions- und Geschwindigkeitsschätzung	103
5.2.2	Nachträgliche Konturschätzung	106
5.2.3	Folgeverhalten der Zustandsschätzung bei Vollbremsung der Objekt- hypothese	110
5.2.4	Einsatz im realen Straßenverkehr	113
5.2.5	Fazit	114
5.3	Fusion von objekt- und graphenbasierten Darstellungsformen	116
5.3.1	Konformes Verhalten bezüglich der Straßenverkehrsordnung	116
5.3.2	Nicht konformes Verhalten bezüglich der Straßenverkehrsordnung	126
5.3.3	Fazit	134
5.4	Fusion von objekt- und gitterbasierten Darstellungsformen: Initialisierungs- verhalten	135
5.5	Ressourcenbedarf des Algorithmus	137
5.6	Anwendungsbeispiel	139
5.7	Fazit	140
6	Zusammenfassung und Ausblick	142
	Literatur	146

Symbolverzeichnis

Konventionen

(nach Bar-Shalom u. a. 2011)

Zustände	im Allgemeinen Vektoren:	
	kleine Buchstaben	z. B.: \mathbf{x}
geschätzte Zustände	im Allgemeinen Vektoren:	
	kleine Buchstaben und $\hat{}$	z. B.: $\hat{\mathbf{x}}$

Weitere Konventionen

Skalare	kleine Buchstaben	z. B.: a
Vektoren	kleine Buchstaben	z. B.: \mathbf{x}
Matrizen	große Buchstaben	z. B.: \mathbf{P}

Skalare

(Abschnittsübergreifend verwendete)

r	gemessene radiale Entfernung (Bestandteil des Messvektors)
ϕ	gemessener Winkel (Bestandteil des Messvektors)
a	gemessene Amplitude
x	x-Position (Bestandteil des Zustandsvektors)
y	y-Position (Bestandteil des Zustandsvektors)
v_x	x-Geschwindigkeit (Bestandteil des Zustandsvektors)
v_y	y-Geschwindigkeit (Bestandteil des Zustandsvektors)
d	Durchmesser (zeitlich konstanter Parameter des Zustandsvektors, vgl. Abschnitt 4.2)
ψ	Lagewinkel (Bestandteil des erweiterten Zustandsvektors)
w	Breite (zeitlich konstanter Parameter des Zustandsvektors)
l	Länge (zeitlich konstanter Parameter des Zustandsvektors)
μ_{ij}	Übergangswahrscheinlichkeit, Wechsel vom Zustand i in den Zustand j

Vektoren

(Abschnittsübergreifend verwendete)

- x** Zustandsvektor
- z** Messvektor

Matrizen

(Abschnittsübergreifend verwendete)

- F** Zustandsübergangsmatrix
- P** Zustandskovarianzmatrix
- Q** Prozesskovarianzmatrix
- R** Messkovarianzmatrix
- H** Messmatrix
- S** Innovationskovarianzmatrix
- W** Kalman-Filtermatrix
- P_{ij}** Die a priori zu bestimmende Übergangsmatrix von Modell i nach Modell j

Abkürzungen

(Abschnittsübergreifend verwendete)

- AIMM** Active Interacting Multi Model (-Filter)
- EKF** Extended Kalman Filter
- IMM** Interacting Multi Model (-Filter)
- LIDAR** Light Detection and Ranging
- NEES** Normalisiertes Fehlerquadrat
(Normalized Estimation Error Squared)
- NIS** Normalisiertes Quadrat der Innovation
(Normalized Innovation Squared)
- RADAR** Radio Detection and Ranging
- RMSE** Mittelwert der Wurzel des quadratischen Fehlers
(Root Mean Square Error)
- ZA** Zeitliche Abdeckung

Kurzfassung

Durch die zunehmende Urbanisierung und die verhältnismäßig hohe Anzahl von Unfällen mit Personenschäden in Kreuzungsbereichen gibt es einen wachsenden Bedarf an maschinellen Wahrnehmungssystemen für das urbane Umfeld. Die Wahrnehmung von bewegten Objekten in urbanen Umgebungen stellt Sensorik und weiterverarbeitende Algorithmen vor erweiterte Herausforderungen. Tracking-Algorithmen müssen gleichzeitig eine Vielzahl von Objekthypothesen stabil verfolgen und dabei sowohl Längs- als auch Querverkehr beherrschen. Bisher verfügbare Seriensysteme sind auf Längsverkehr und eine eingeschränkte Anzahl an Objekthypothesen optimiert. Realisierungen in aktuellen Forschungsbeiträgen nutzen zum Teil aufwändige Sensorsetups und fusionieren diese beispielsweise in objekt-, gitter- und graphenbasierten Darstellungsformen. Zur Verbesserung des Szenenverständnisses werden diese Darstellungsformen anschließend typischerweise zu einem Umfeldmodell kombiniert.

Im Rahmen dieser Arbeit wird auf aufwändige Sensorsetups verzichtet. Stattdessen wird eine konkrete Realisierung eines maschinellen Wahrnehmungssystems für das urbane Umfeld mittels eines seriennahen Laserscanners analysiert. Hierfür wird eine strukturelle Erweiterung des sogenannten Interacting-Multi-Modell-Filters um Fusionen mit graphen- und gitterbasierten Darstellungsformen erarbeitet, die die Unsicherheit der Zustandsschätzung in Kreuzungsbereichen minimiert. Die Eigenschaften der neuartigen Erweiterung zum Active-Interacting-Multi-Modell-Filters (AIMM) werden anschließend anhand realer Messdaten validiert.

Abstract

Increasing urbanization results in a higher risk of accidents at intersections. This makes it necessary to improve machine perception systems in urban environments. The perception of moving objects in urban environments poses new challenges for sensors and tracking algorithms. Tracking algorithms must estimate the movement of a large number of objects simultaneously while taking into account longitudinal as well as crossing traffic. The systems currently available are only able to handle motorway traffic and a limited number of objects. In order to extend the application area of machine perception systems, several ongoing research projects attempt to use sophisticated sensor setups and fuse the data into object-, grid- and graph-based representations. These representations are combined to a single model of the environment, which is necessary to transfer the output to application scenarios.

Aiming at closing this gap, the work presented in this thesis analyzes a concrete realization of a machine perception system for urban environments using a close-to-production laser scanner. An extension of the interacting multi model filter is used to minimize the uncertainty of state estimation in urban crossroads so that graph and grid-based forms of representation can be merged. Finally, the active interacting multi model filter (AIMM) is evaluated by using real sensor data.

1 Einleitung

1.1 Motivation

In Europa verloren im Jahr 2009 mehr als 35.000 Menschen bei Verkehrsunfällen ihr Leben, zudem wurden mehr als 1,5 Millionen Menschen verletzt (vgl. Com 2010). Die Europäische Union hat sich daher erneut das Ziel gesetzt, die Zahl der Verkehrstoten in Europa bis zum Jahr 2020 zu halbieren. Dieses Ziel wurde zuvor bereits für das Jahr 2010 definiert, jedoch nicht erreicht (siehe Com 2010). Abbildung 1.1 zeigt die Daten des statistischen Bundesamtes, wonach die Gesamtzahl der Unfälle mit Personenschäden im Zeitraum zwischen den Jahren 1991 und 2010 um ca. 25% zurückgegangen ist. Hierbei ist der Rückgang außerorts jedoch mit über 30% höher als innerorts mit knapp 20%. Weitere Auswertungen dieser Daten ergeben, dass sich im Jahr 2009 *ca. 70% aller Unfälle mit Personenschaden innerorts ereignet* haben. Im Jahr 1991 betrug dieser Anteil noch ca. 64% und ist seit dem kontinuierlich angestiegen. Zu vergleichbaren Ergebnissen kommt zum einen eine detaillierte Auswertung von Unfalldatenbanken im Rahmen des öffentlich geförderten Projektes Intersafe2 (vgl. Knaup u. a. 2009), zum anderen eine Auswertung in Meitinger (2008). Ursachen für Unfälle in Ortschaften sind z. B. Fehlbewertungen der Situation durch den Fahrer und Unaufmerksamkeit des Fahrers. Weitere Ursachen von Unfällen mit Personenschäden sind nicht angepasste Geschwindigkeit, zu geringer Abstand und Umwelteinflüsse, wie z. B. Glätte. Innerorts bietet sich somit ein großes Wirkungsfeld mit wachsendem Potenzial, um das langfristige Ziel der Reduzierung von Unfällen mit Personenschäden zu erreichen.

Ein merklicher Beitrag zur Verringerung der Unfallzahlen und damit zur Erreichung dieses Zieles soll durch *aktive Sicherheitssysteme* geleistet werden. Aktive Sicherheitssysteme können, durch eine maschinelle Umfeldwahrnehmung und eine Situationsinterpretation, prinzipiell bereits eingreifen bevor überhaupt eine kritische Situation entsteht und somit Unfallfolgen mindern oder sogar Unfälle verhindern (vgl. Reif 2009, S. 291 ff.). Dadurch unterscheiden sich diese Systeme von passiven Sicherheitssystemen wie z. B. Airbags. Weitere Beiträge zur Verringerung der Zahl der Verletzten und Verkehrstoten im Falle eines Unfalls sollen durch die Verbesserung der passiven Sicherheit und die Automatisierung der Unfallmeldung geliefert

werden. *Fahrerassistenzsysteme* unterstützen und entlasten den Fahrer bei der Fahraufgabe oder übernehmen Teilaufgaben. Mittels unterschiedlicher Sensoren erfassen diese Systeme den Zustand des Fahrzeuges und/oder der Umgebung. Durch das so gebildete Szenenverständnis erhöhen diese Systeme den Fahrkomfort, indem sie den Fahrer darin unterstützen, das Fahrzeug zu führen. Andere Systeme warnen den Fahrer vor einer gefährlichen Situation oder entschärfen die Situation durch einen Eingriff in die Fahrzeugaktuatorik.




Bild 1.1: Entwicklung der Unfallzahlen (Unfälle mit Personenschäden) in Deutschland in den Jahren 1991 (Basis) - 2010 ¹.

Durch die zunehmende Urbanisierung und das hohe Potenzial, speziell bei der Verringerung von Unfällen mit Personenschäden, ist die *Bedeutung komplexer urbaner Einsatzumgebungen* für Fahrerassistenzsysteme unverändert hoch. Basis eines jeden den Fahrer in kritischen Situationen unterstützenden Fahrerassistenzsystems ist eine *maschinelle Umfeldwahrnehmung*. Mittels der maschinellen Wahrnehmung erstellen diese Systeme ein Umfeldmodell. Nach Mählich (2009) ist das Umfeldmodell eine symbolische Ebene zwischen der maschinellen Umfelderkennung mittels Sensoren und den auf der Interpretation des Umfeldmodells basierenden Handlungen des Fahrzeuges. Es beinhaltet Modelle über den Zustand des eigenen Fahrzeuges sowie die Zustände der Umgebung. Fahrerassistenzsysteme haben bisher in gut strukturierten Umgebungen (statisch beim Einparken, klare Struktur auf der Autobahn) Einzug in die Serienproduktion gehalten. Ein weiteres Voranschreiten der Fahrerassistenz,

¹Datenquelle: Statistisches Bundesamt, Wiesbaden: Verkehrsunfälle, Unfallentwicklung im Straßenverkehr, 2011.

beispielsweise auch in die, für den Fahrer besonders gefährlichen Kreuzungssituationen in der Stadt, ist bisher an den Einschränkungen durch die maschinelle Umfeldwahrnehmung (vgl. Effertz 2008) gescheitert.

1.2 Herausforderungen für die objektbasierte maschinelle Umfeldwahrnehmung in urbaner Umgebung

Die Umfeldwahrnehmung in urbanen Umgebungen stellt Sensorik und weiterverarbeitende Algorithmen vor neue Herausforderungen, wie beispielsweise das gleichzeitige Verfolgen einer Vielzahl von Verkehrsteilnehmern *ohne die, z. B. auf der Autobahn übliche einheitliche Bewegungsrichtung* (vgl. Leonard u. a. 2008, Rauskolb u. a. 2008 und Roessler 2010). Darüber hinaus ist in Kreuzungssituationen die Zeitspanne zwischen dem Eintritt eines Objektes in den Sensorsichtbereich und einer im Extremfall möglichen Kollision sehr kurz. So ergibt sich für eine Situation, in der sich zwei Objekte in Längsrichtung mit jeweils $54 \frac{km}{h}$ nähern, unter der Annahme, dass sich die Objekte gegenseitig in 75m Entfernung detektieren, eine Zeitspanne von 2,5s bis zu einer möglichen Kollision. Im Kreuzungsbereich besteht außerdem die Herausforderung, dass *unterschiedliche Arten von Verkehrsteilnehmern* mit verschiedenen Konturformen zu berücksichtigen sind. Hierbei liegt eine besondere Herausforderung in der Tatsache, dass nicht nur PKW, LKW und Motorräder, sondern zusätzlich z. B. auch Fahrradfahrer oder Fußgänger zu berücksichtigen sind. Außerdem wird verlangt *die in Kreuzungssituationen auftretende Querdynamik* (abbiegender Verkehr) und die Längsdynamik (beschleunigender oder bremsender Verkehr) der Verkehrsteilnehmer zu berücksichtigen. Hierbei ist zu beachten, dass die auftretende Dynamik beispielsweise bei PKW in Kreuzungsbereichen mit $4,5 \frac{m}{s^2}$ (vgl. Schimmelpfennig u. Nackenhorst 1985) deutlich höher ist, als mit ca. $2 \frac{m}{s^2}$ z. B. für ein Komfortsystem auf der Autobahn.

Im urbanen Umfeld wird die maschinelle Wahrnehmung vor eine Vielzahl neuer Herausforderungen gestellt. Relevant sind im Kontext dieser Arbeit vor allem die wechselnde Querdynamik, der Umgang mit Längs- und Querverkehr und die unterschiedlichen Verkehrsteilnehmer.

1.3 Technische Ziele der objektbasierten maschinellen Umfeldwahrnehmung in urbaner Umgebung

Die technischen Ziele eines objektbasierten maschinellen Wahrnehmungssystems im urbanen Umfeld und die daraus an das System entstehenden Anforderungen werden im Folgenden dargestellt:

- **Öffnungswinkel:** Es besteht der Anspruch, dass der Öffnungswinkel der Sensorik möglichst nahezu 180° beträgt, um auch Querverkehr rechtzeitig zu detektieren.
- **Reichweite:** Um den Fahrer auch beim Linksabbiegen mit ungefähr $50 \frac{km}{h}$ rechtzeitig vor einem herannahenden Fahrzeug (im Extremfall ebenfalls $50 \frac{km}{h}$) zu warnen, wird eine minimale Reichweite des Sensors von ca. 80m postuliert (nach Roessler 2010). Dies reicht aus, um bei einer Annäherung an eine Kreuzung genug Zeit für Warn- und Interventionsstrategien zur Verfügung zu stellen. Berechnungen im Rahmen von Intersafe2 setzen für die eingesetzte Sensorik Reichweiten von 77m für die beiden oben vorgestellten Szenarien (INT 2011) voraus. Da sich Verkehrsteilnehmer im Kreuzungsbereich häufig sehr nahe kommen, ist eine minimale Reichweite von möglichst 0m wünschenswert.
- **Detektionsfähigkeit:** Die eingesetzte maschinelle Umfeldwahrnehmung hat das Ziel, sowohl Längs- als auch Querverkehr zu detektieren und dabei eine Vielzahl von Verkehrsteilnehmern unterschiedlicher Gattungen (PKW, LKW, Radfahrer, Fußgänger) zu berücksichtigen. Außerdem ist es das Ziel, die durch Verdeckung bzw. Teilverdeckung und Perspektivwechsel entstehenden Einflüsse zu berücksichtigen.
- **Verfügbare Informationen:** Es ist das Ziel der maschinellen Umfeldwahrnehmung, Informationen über Geschwindigkeit, Position, Ausdehnung und nach Möglichkeit den Lagewinkel der Objekthypothesen zu liefern. Dies wird für Längs- und Quer- und für abbiegenden Verkehr gefordert. Ferner besteht das Ziel, die Algorithmen robust gegenüber Perspektivwechseln zu gestalten. Perspektivwechsel treten üblicherweise bei Abbiegevorgängen und damit besonders in Kreuzungsbereichen auf.
- **Detektionslatenz und Echtzeitfähigkeit:** Das eingesetzte maschinelle Wahrnehmungssystem hat das Ziel, dass Sensor und verarbeitende Algorithmen möglichst schnell stabile Informationen über den Zustand eines Objektes liefern sollen. Vor allem für eine aus der Sicht nachfolgender Algorithmen rechtzeitige Erkennung von Querverkehr ist dies entscheidend. Für eine erstmalige stabile Schätzung von Position und Geschwindigkeit benötigt ein Tracking-Algorithmus, abhängig von der eingesetzten Sensorik, ca.

2-4 Messzyklen. Multipliziert mit der Zykluszeit des Sensors ergibt sich hieraus die sogenannte Detektionslatenz. Im urbanen Umfeld ist diese Zeitspanne von der konkreten Applikation abhängig. Für diese Arbeit wird als Ziel definiert, die Detektionslatenz zu minimieren. Ein weiteres Ziel ist die Echtzeitfähigkeit der Algorithmen. Diese wird in diesem Zusammenhang wie folgt definiert: Es wird verlangt, dass die Algorithmen für alle Objekte innerhalb eines Sensormesszyklus zu berechnen sind.

- **Messrichtigkeit:** Um auch in 80m Entfernung noch eine fahrspurgenaue Positionsschätzung durchzuführen, sind eine Winkelrichtigkeit von mindestens 1° und eine Entfernungsrichtigkeit von mindestens 1m notwendig.

1.4 Ziele und Gliederung der Arbeit

Im Kapitel **Stand der Forschung und Technik (Kapitel 2)** werden ausgewählte nationale und internationale Forschungsprojekte und deren Zielsetzung im Bereich der aktiven Sicherheitssysteme, vor allem mit Bezug zum urbanen Umfeld, erläutert. Die vorgestellten Systeme benötigen eine ihren Anforderungen entsprechende Umfeldwahrnehmung. Anhand einiger Beispiele wird der Stand der Technik in der maschinellen Umfeldwahrnehmung für das urbane Umfeld analysiert. Hieraus werden die Ziele dieser Arbeit motiviert. Der Fokus liegt dabei (wie in der gesamten Arbeit) primär auf laserbasierten Systemen.

Im Kapitel **Methoden und Gütekriterien (Kapitel 3)** wird eine Entwicklungsumgebung für die objektbasierte, maschinelle Umfeldwahrnehmung von modernen Fahrerassistenzsystemen diskutiert. Zum einen werden die Vorteile der Kombination von modellbasierter und auf Messdaten basierender Entwicklung aufgezeigt. Zum anderen wird eine Toolkette vorgestellt, die es ermöglicht, diese Kombination effektiv zu nutzen und dabei eine Referenzier- und Bewertbarkeit der Algorithmen zu ermöglichen. Zur Referenzierung und Bewertung sind objektive Gütekriterien notwendig. Daher wird in diesem Kapitel ein Ansatz für Gütekriterien zur Bewertung von Objekttracking-Algorithmen diskutiert.

Lösungsansätze zum Überwinden der im Kapitel **Stand der Technik** identifizierten technischen Grenzen werden im Kapitel **Technischer Lösungsansatz: Urbanes Objekttracking im Kontext hybrider Umfeldmodelle (Kapitel 4)** erläutert. Hierfür werden Zustands- und Dynamikmodelle erarbeitet und ein Verfahren zur nachträglichen Konturschätzung vorgestellt. Überdies wird eine strukturelle Erweiterung zum Active-Interacting-Multi-Model-Filter (AIMM) mit einer Anbindung von Hintergrundinformationen zur Verbesserung der Modellierung der Querdynamik von abbiegenden Objekten analysiert. Zudem

wird ein Verfahren beschrieben, das Informationen über das Verhalten vorheriger Objekthypothesen zur beschleunigten Initialisierung von Objekten nutzt.

Die **Experimentelle Validierung des technischen Lösungsansatzes (Kapitel 5)** zeigt Eigenschaften, Vorteile und Grenzen der vorgestellten Verfahren auf. Hierzu werden die in Kapitel 3 vorgestellten Gütekriterien auf reale Mess- und Referenzdaten angewendet. Die Evaluierung der Algorithmen erfolgt hierbei einerseits im Prüfgelände und andererseits im realen Straßenverkehr.

Schlussbemerkungen und Ausblick (Kapitel 6) liefert eine Zusammenfassung der zentralen Thesen dieser Arbeit und gibt einen Ausblick auf weiterführende Fragestellungen, die in dieser Arbeit aufgeworfen werden.

2 Stand der Forschung und Stand der Technik

Für die Beschreibung des aktuellen Standes der Technik werden zunächst ausgewählte internationale Forschungsaktivitäten zum Thema aktive Sicherheits- bzw. Fahrerassistenzsysteme im urbanen Umfeld vorgestellt (siehe Abschnitt 2.1). Anhand deren grundlegender Ziele und Ideen werden allgemeine Trends in diesem Bereich aufgezeigt. Anschließend werden einige für das Verständnis des Kapitels notwendige Grundlagen erläutert (siehe Abschnitt 2.2, dieser Abschnitt kann nach Bild 2.1 von mit den Grundlagen vertrauten Lesern ausgelassen werden). Im weiteren Verlauf werden technische Realisierungen und Ansätze aus aktuellen Forschungsaktivitäten zum Themen Objekttracking bzw. Zustandsschätzung im urbanen Umfeld vorgestellt (siehe Abschnitt 2.3). Diese werden anschließend diskutiert und weiterführender Forschungsbedarf identifiziert.




Bild 2.1: Grafische Darstellung der Gliederung von Kapitel 2

2.1 Allgemeine Forschungsaktivitäten: Aktive Sicherheitssysteme im urbanen Umfeld

Eine Auswahl japanischer, deutscher und europäischer Forschungsprojekte, rund um aktive Sicherheitssysteme im urbanen Umfeld, wird im Folgenden vorgestellt und diskutiert. Anschließend werden die Trends dieser Forschungsaktivitäten resümiert (vgl. Bild 2.2).




Bild 2.2: Grafische Darstellung der Gliederung von Kapitel 2.1

2.1.1 Europäische Forschungsaktivitäten

Zurzeit beschäftigen sich zahlreiche öffentlich geförderte Forschungsaktivitäten mit aktiven Sicherheitssystemen für das urbane Umfeld. Eine Auswahl international geförderter Forschungsprojekte mit besonderem Bezug zu dieser Arbeit (Intersafe2, GENEVA, SAFESPOT und InterActive) wird im Folgenden erläutert.

Cooperative Intersection Safety (Intersafe2)

Das Projekt Intersafe2¹ beschäftigt sich mit dem Thema *kooperative Kreuzungssicherheit* und ist ein von der EU gefördertes Projekt aus dem 'Seventh Framework Programme'. Ziel von Intersafe2 war es, einen Kreuzungsassistenten zu entwickeln, der es an Kreuzungen ermöglicht, die Anzahl der Unfälle mit Personenschäden nennenswert zu reduzieren. Dieses System warnt den Fahrer vor qualifizierten Rotlicht- und Stoppschildverstößen und fernerhin vor Unfällen mit Objekten. Hierbei werden neben den in den Versuchsfahrzeugen verbauten Sensoren, ebenfalls Ortungssysteme und Navigationskarten genutzt. Zudem werden Car2Car-Kommunikation zwischen verschiedenen Fahrzeugen und Car2Infrastructure-Kommunikation zwischen ebenfalls mit Sensoren ausgestatteten Kreuzungen eingesetzt. Das Projekt war auf 36 Monate ausgelegt und endete im Mai 2011. Das im Kontext dieser Arbeit vorgestellte maschinelle Wahrnehmungssystem ist unter anderem im Rahmen von Intersafe2 eingesetzt und getestet worden. Für den Kontext dieser Arbeit ist hauptsächlich der in Intersafe2 verfolgte Ansatz, verschiedene Datenquellen (Navigationsdaten, Car2X-Kommunikation und On-Board-Sensorik) zu einem Umfeldmodell für urbane Umgebungen zu fusionieren, relevant.

Galileo / EGNOS Enhanced Driver Assistance (GENEVA)

Das von der EU im Rahmen des 'Seventh Framework Programme' geförderte Projekt GENEVA² beschäftigt sich mit der Entwicklung eines Kreuzungsassistenten ('UrbanAssist'), der auf gängigen Satelliten-Ortungssystemen basiert. Dieser Kreuzungsassistent unterstützt

¹Quelle: www.intersafe-2.eu, abgerufen am 04.11.2011

²Quelle: www.geneva-fp7.eu, abgerufen am 04.11.2011

den Fahrer beim Linksabbiegen und warnt ihn vor dem unbeabsichtigten Überfahren einer Stopplinie. Um den Fahrer in komplexen Kreuzungssituationen zu unterstützen, benötigen beide Funktionen ein genaues Umfeldmodell. Dieses wird aus einer Fusion aus Car2X-Kommunikation, Navigationsdaten und On-Board-Sensorik generiert. Für die Fusion dieser Daten und einer darauf aufbauenden Funktion sind hochgenaue Ortungslösungen notwendig. Diese sind bisher nur mit aufwändigen Koppelnavigationssystemen möglich. Im Projekt GENEVA wurde daher bis Ende 2011 eine *hochgenaue und kostengünstige Ortungslösung* auf Basis der Fusion eines gängigen Satelliten-Ortungssystems und im Fahrzeug serienmäßig verbauter Intertialsensorik entwickelt. Zugleich stehen Algorithmen zur Bewertung der aktuellen Positions- und Navigationskartengüte im Fokus des Projektes. Diese sind notwendig, um die oben beschriebenen Funktionen auf die aktuelle Datengüte anzupassen und Fehlauflösungen zu vermeiden. Das im Kontext dieser Arbeit vorgestellte maschinelle Wahrnehmungssystem ist ebenfalls im Rahmen von GENEVA eingesetzt worden. Ausschlaggebend für die vorliegende Arbeit ist der in GENEVA verfolgte Ansatz, günstige und genaue Ortungslösungen zu realisieren. Zusätzlich sind Algorithmen zur Bewertung der Güte von Position und Navigationskarten relevant.

Cooperative vehicles and road infrastructure for road safety (SAFESPOT)

Das im Rahmen des 'Sixth Framework Programme' der EU geförderte Projekt SAFESPOT³ beschäftigte sich bis zum Jahr 2010 mit einem Fahrerassistenzsystem, dessen Umfeldmodell aus der Fusion von Daten aus Car2Infrastructure-Kommunikation, Car2Car-Kommunikation und On-Board-Sensorik generiert wird. Ziel des Projektes war hierbei unter anderem die Entwicklung von Algorithmen zur Fusion dieser Daten. Hierfür wurde unter dem Namen Local Dynamic Map (LDM) ein Umfeldmodell entwickelt, das aus unterschiedlichen Abstraktionsebenen besteht. Darüber hinaus wurde ein Kreuzungsassistent realisiert, der den Fahrer, auf Basis des oben beschriebenen Umfeldmodells, frühzeitig vor Kollisionen mit anderen Verkehrsteilnehmern warnt und ihm so die Möglichkeit gibt, rechtzeitig zu reagieren. Hierzu gehört unter anderem auch das Erkennen von z. B. Fußgängern oder Radfahrern. Weitere Situationen sind das Erkennen von Verkehrszeichen, die Warnung vor herannahenden Wegerechtsfahrzeugen, das Warnen vor stark bremsenden Verkehrsteilnehmern und das Sichtbarmachen nicht einsehbarer Verkehrssituationen. Relevant für diese Arbeit ist der in SAFESPOT verfolgte Ansatz eines navigationskartenbasierten Umfeldmodells mit mehreren Abstraktionsebenen.

³Quelle: www.safespot-eu.org, abgerufen am 04.11.2011

Accident avoidance by active intervention for Intelligent Vehicles (interactIVe)

Das von der EU im Rahmen des 'Seventh Framework Programme' geförderte Projekt interactIVe⁴ beschäftigt sich bis Mitte 2014 mit einer einheitlichen Architektur für aktive Sicherheitssysteme und tritt damit die direkte Nachfolge des Projektes Preventive safety applications and technologies (PReVENT) an. Ziel des Projektes ist es, unnötige Redundanzen zu beseitigen und eine Architektur zu schaffen, auf der verschiedene Funktionen realisiert werden. Dies bedeutet unter anderem auch, dass es das Ziel ist, die Daten verschiedener On-Board-Sensoren in einem *einheitlichen Umfeldmodell* zu fusionieren. Dieses einheitliche Umfeldmodell ist die Basis für die verschiedenen Funktionsausprägungen. Diese Vereinheitlichung wird die Kosten solcher Sicherheitssysteme deutlich senken und einen Einsatz auch unterhalb der Oberklasse möglich werden lassen. Dabei stehen drei Funktionen im Fokus: Fahrerunterstützung, Minderung von Unfallfolgen (Collision Mitigation) und Unfallvermeidung (Collision Avoidance). Für diese Arbeit ist speziell der in interactIVe verfolgte Ansatz der Fusion verschiedener Datenquellen in einem einheitlichen Umfeldmodell relevant. Dieses Umfeldmodell bildet die Basis für verschiedene Funktionsausprägungen.

2.1.2 Japanische Forschungsaktivitäten

Während die Zahl der Verkehrsunfälle mit Personenschäden in vielen hoch motorisierten Ländern seit 1970 deutlich zurückgegangen ist (z. B. Deutschland - 25%, USA -15%) ist die Anzahl in Japan nahezu konstant geblieben (+3%)⁵. Das Risiko, bei einem Verkehrsunfall verletzt zu werden, ist in Japan pro Fahrzeugkilometer 2-3-mal höher als in Deutschland oder den USA (Quelle: IRTAD (International Road Traffic and Accident Database), 103 Unfälle mit Personenschäden pro 100 Millionen Fahrzeugkilometer in Japan, 48,5 in Deutschland und 34,9 in den USA, Stand 2008). Daher stehen aktive Sicherheitssysteme in Japan im Fokus zahlreicher öffentlich geförderter Forschungsvorhaben.

Das Projekt AHS (Smartway)⁶ gefördert durch das MLIT (Ministry of Land, Infrastructure and Transport) ist ein auf Car2Infrastructure-Kommunikation basierendes System, das sich aktuell in Feldtests befindet und für ein Mautsystem eingesetzt wird. Das System ist primär auf Autobahnen installiert. Es warnt vor Stauenden, unterstützt beim Einfädeln auf die Autobahn und bietet darüber hinaus Bezahlfunktionen für die Maut und das Tanken. Das System basiert auf an den Straßen installierten DSRC-Barken (Dedicated Short Range Communication). Die Funkfrequenz liegt bei 5,8GHz. 2008 waren 26 Millionen Systeme an

⁴Quelle: www.interactive-ip.eu, abgerufen am 04.11.2011

⁵Quelle: internationaltransportforum.org/irtadpublic/pdf/10IrtadReport.pdf, abgerufen am 04.11.2011

⁶Quelle: wiki.fot-net.eu/index.php?title=Smartway, abgerufen am 15.03.2012

Japans Straßen installiert.

Das Vorhaben DSSS (Driving Safety Support System)⁷, gefördert durch die National Police Agency und Universal Traffic Managment Society (UTMS), ist ein auf Car2Infrastructure-Kommunikation basierendes System, das sich aktuell in Feldtests befindet. Das System wird unter anderem in Kreuzungsbereichen eingesetzt. Es warnt vor Stopp- und Rotlichtverstößen, Stauenden und Kollisionen mit anderen Verkehrsteilnehmern (auch Fußgängern). Es basiert auf Infrarotbaken, die entlang der Straßen angebracht werden.

Das Projekt ASV (Advanced Safety Vehicle)⁸ ist ein durch das MLIT (Ministry of Land, Infrastructure and Transport) gefördertes Projekt, das sich aktuell in der vierten Phase befindet. Ziel ist hier die Entwicklung einer infrastrukturunabhängigen Warnung, unter anderem in Kreuzungsbereichen. Hierfür wird Car2Car-Kommunikation eingesetzt, intelligente Infrastruktur wird nicht genutzt. Als Funkstandard wird DSRC (Dedicated Short Range Communication) verwendet.

Haupttrend in japanischen Forschungsaktivitäten ist derzeit die Untersuchung kommunikationsbasierter Fahrerassistenzsysteme. Hierbei werden neben Systemen, die eine intelligente Infrastruktur benötigen (Untersuchungen in großen Feldtests), auch Systeme mit direkter Kommunikation zwischen den Verkehrsteilnehmern untersucht. Beide Ansätze adressieren unter anderem auch urbane Kreuzungssituationen.

2.1.3 Deutsche Forschungsaktivitäten

Das Projekt Aktiv⁹ beschäftigte sich bis Mitte 2010 im Projekt Aktive Sicherheit unter anderem mit Assistenzsystemen für Kreuzungssituationen. Adressiert werden hierbei drei Szenarien: Querverkehr, Linksabbiegen und Auffahrunfälle an Lichtsignalanlagen. Hierbei werden sowohl On-Board als auch kommunikationsbasierte Technologien eingesetzt. Die Kommunikation zwischen den Verkehrsteilnehmern basierte hierbei auf dem Funkstandard 802.11p. Die prototypische Realisierung der Querverkehrsassistenz basiert hierbei auf kommunikationsbasierten Technologien. Für das Linksabbiege- und das Ampelassistenzsystem wird eine Fusion aus Car2X-Kommunikation und On-Board-Sensoren (Je nach Versuchsträger verschiedene Kombinationen aus Radar, Lidar und Stereo-Kamera) verwendet.

⁷Quelle: www.utms.or.jp/english/system/dsss.html, abgerufen am 15.03.2012

⁸Quelle: www.iatss.or.jp/pdf/research/27/27-2-11.pdf, abgerufen am 15.03.2012

⁹Quelle: www.aktiv-online.de, abgerufen am 25.02.2013

2.1.4 Trends in den Forschungsaktivitäten und abgeleitetes Fazit

Der Blick auf die Projekte Intersafe2, SAFESPOT, DSSS, ASV und Aktiv zeigt, dass das Voranschreiten der Fahrerassistenz in urbanen und damit komplexen Umgebungen im Fokus zahlreicher, öffentlich geförderter Forschungsprojekte steht. Des Weiteren zeigen die beispielhaft aufgeführten Projekte, dass *aufwändige Umfeldmodelle* nötig sind, um den Herausforderungen der urbanen Umwelt gewachsen zu sein. Hierfür werden vor allem Fusionen aus On-Board-Sensorik, Navigationsdaten und Car2X-Kommunikation in aktuellen Forschungsvorhaben untersucht. Daher benötigen diese Verfahren eine *hochgenaue Ortungslösung* und Algorithmen zur Bewertung von aktueller Karten- und Ortungsqualität. Diese sind nach aktuellem Stand der Technik nur durch aufwändige satellitengestützte Koppelnavigationssysteme möglich. Das Projekt GENEVA beschäftigt sich daher damit, solche Ortungslösungen in Zukunft deutlich günstiger und mit heute schon im Fahrzeug serienmäßig verbauten Komponenten zu realisieren. Bei der On-Board-Sensorik werden Fusionen verschiedener Sensoren eingesetzt. Um die Gesamtsysteme günstiger zu machen, strebt das Projekt interactIVe eine *gemeinsame Architektur* an, auf der verschiedene Fahrerassistenzsysteme realisiert werden. Dieses Vorgehen soll vermeiden, dass Systeme Sensoren exklusiv verwenden und somit Sensoren redundant verbaut werden. Ziel ist es, ein einheitliches Umfeldmodell, das auf der Fusion mehrerer Datenquellen basiert, zu erzeugen, und dieses verschiedenen Funktionen zur Verfügung zu stellen. Somit wird es zunehmend wichtiger, Algorithmen zu entwickeln, die ein generisches Umfeldmodell erzeugen und es so ermöglichen, dieses für eine Vielzahl von Funktionen nutzbar zu machen.

2.2 Wahrnehmungs-Grundlagen und Filter-Verfahren

In diesem Kapitel werden einige allgemeine, für das Verständnis des Abschnitts 2.3 notwendige Grundlagen bezüglich der verwendeten Sensortechnologie (Abschnitt 2.2.2) und eine Auswahl verbreiteter Tracking-Verfahren vorgestellt. Mit den Partikelfiltern (Abschnitt 2.2.3), den Kalman-Filtern (Abschnitt 2.2.4) und dessen Erweiterungen (Abschnitt 2.2.5) werden die gängigsten, für diese Arbeit relevanten, Verfahren theoretisch vorgestellt (vgl. Bild 2.3).




Bild 2.3: Grafische Darstellung der Gliederung von Kapitel 2.2

Projekt	Gegenstand	Ziel
Intersafe2	Kreuzungsassistentz	Validierung Umfeldmodell: Fusion Navigationsdaten, Car2X-Kommunikation und On-Board-Sensorik
SAFESPOT	Kreuzungsassistentz	Validierung Umfeldmodell: Fusion Navigationsdaten, Car2X-Kommunikation und On-Board-Sensorik
DSSS	Kreuzungsassistentz	Feldtest: Car2Infrastructure-Kommunikation
ASV	Kreuzungsassistentz	Validierung: Car2Car-Kommunikation
GENEVA	Ortungssysteme Kreuzungsassistentz	Validierung: kostengünstige Ortungslösung
interactIVe	Systemarchitektur	Validierung: einheitliches Umfeldmodell
AHS	Autobahnen	Feldtest: Car2Infrastructure-Kommunikation
Aktiv - Kreuzungsassistentz	Kreuzungsassistentz	Validierung Umfeldmodell: Fusion Navigationsdaten, Car2X-Kommunikation und On-Board-Sensorik

Tabelle 2.1: Tabellarische Übersicht japanischer und europäischer Forschungsaktivitäten.

2.2.1 Begrifflichkeiten

Allgemein wird bei der maschinellen Umfeldwahrnehmung im automobilen Umfeld zwischen aktiver (z. B. Laser, Radar, Ultraschall) und passiver (z. B. Kamerasysteme) Sensorik unterschieden. Während der Mensch das Fahrzeugumfeld vor allem mit den Augen wahrnimmt, hat sich in der maschinellen Umfeldwahrnehmung eine Mischung aus *aktiver und passiver Sensorik* etabliert. Jedoch sind die bisher verfügbaren Systeme, meist bestehend aus Radar- und/oder Kamerasystemen für unstrukturierte Umgebungen nur bedingt geeignet und vor allem für den Einsatz in Längsverkehrsszenarien optimiert. So haben die verfügbaren Kamerasysteme nur einen eingeschränkten Öffnungswinkel, während die Radarsysteme technologiebedingt merkliche Schwächen bei der Detektion tangentialer Geschwindigkeiten aufweisen. Somit ist es mit den bestehenden Systemen nur sehr eingeschränkt möglich, beispielsweise kreuzenden Querverkehr mit der erforderlichen Qualität wahrzunehmen. Neben der Weiterentwicklung der bestehenden Technologien hinsichtlich der bekannten Schwächen, stehen *Laserscanner mit großem Öffnungswinkel* im Fokus aktueller Forschungsaktivitäten (vgl. Fürstenberg u. Dietmayer 2004, Boehlau u. a. 2009). Diese bieten mit ihrer Eigenschaft, Informationen über die Kontur des Umfeldes zu liefern, vielversprechendes Potenzial für die Herausforderungen der Umfeldwahrnehmung in unstrukturierten Umgebungen. So ermöglichen es unter anderem Laserscanner auf Grund ihres großen Öffnungswinkels Längs- und Querverkehr zu detektieren. Die Bestimmung von Ausdehnung, Position und Dynamikda-

ten (Zustandshypothesenmodelle) der im Sensorsichtbereich befindlichen Verkehrsteilnehmer (Objekte), ist eine der zentralen Herausforderungen der maschinellen Umfeldwahrnehmung im urbanen Umfeld. Die Erzeugung dieser *Zustandsmodelle* aus einem Strom von Messdaten wird Objekttracking genannt. Die hierfür zu bestimmenden Modelle und verwendeten Begrifflichkeiten werden in Abbildung 2.4 beschrieben und im Folgenden erläutert:

- **Basismerkmale und komplexere Merkmale.** Nach Mählich (2009) wird zwischen Basismerkmalen und komplexeren Merkmalen unterschieden. Zur Unterscheidung werden die Basismerkmale im Folgenden als die durch den Sensor gemessenen Rohdaten bezeichnet. Die durch die Segmentierung entstehenden komplexeren Merkmale werden als segmentierte Rohdaten bezeichnet. Die durch die Transformationsvorschrift des Messmodells entstehenden und im Umfeldmodell verwendeten komplexen Merkmale werden im Folgenden als Merkmale bezeichnet.
- **Das Messmodell** überführt die segmentierten Rohdaten in den im Umfeldmodell verwendeten Merkmalsraum.
- **Das Dynamikmodell** prädiziert aus einem bekannten Zustand den nächsten erwarteten Zustand.
- **Das Sensormodell** stellt den Zusammenhang zwischen Zustandsvektor und Merkmals- bzw. Messvektor dar. Es beschreibt damit die Transformation aus dem Zustands- in den Merkmalsraum.

Im Allgemeinen wird beim Objekttracking zwischen drei Unsicherheitsdomänen (vgl. Mählich 2009) unterschieden:

- **Detektions-/Existenzunsicherheit:** Zufällige Messfehler und physikalisch bedingtes Messrauschen führen zu Unsicherheiten in der Existenz eines Objektes. Daher werden in einem maschinellen Umfeldmodell nur Objekthypothesen abgebildet. Ob hinter einer Objekthypothese ein reales Objekt existiert, ist mit Unsicherheiten behaftet. Messungen werden z. B. fälschlicherweise vom Boden und nicht von einem tatsächlichen Objekt verursacht. In diesem Fall wird eine Objekthypothese fehlerhaft an einer Stelle vermutet, an der real nur der Boden existiert. Andersherum ist es möglich, dass ein real existierendes Objekt z. B. auf Grund seiner Oberflächenbeschaffenheit von einem Sensor nicht gemessen wird. In diesem Fall würde das real existierende Objekt im maschinell erstellten Umfeldmodell nicht berücksichtigt, also zu keiner Objekthypothese führen.

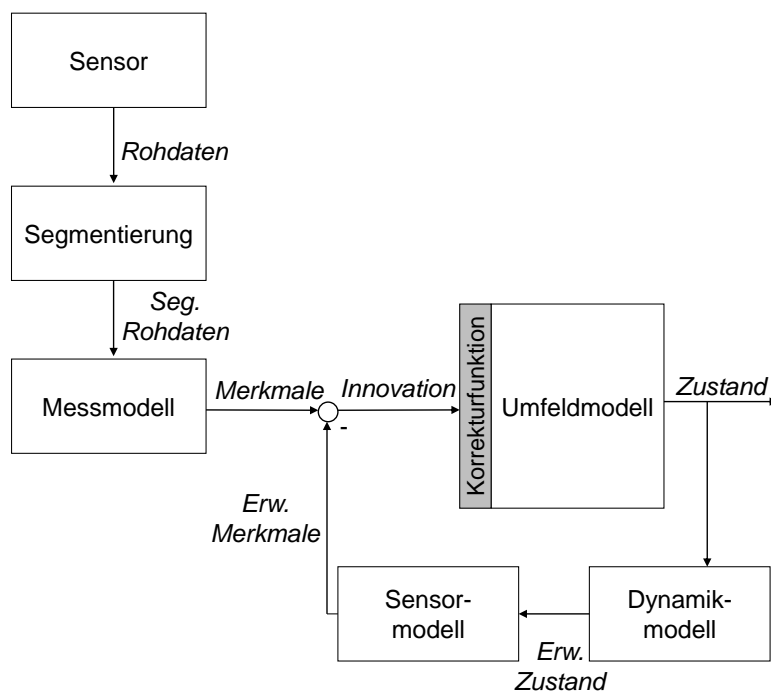


Bild 2.4: Schematische Darstellung der verschiedenen Modelle bei der Umfeldmodellierung durch einen rekursiven Filterprozess (nach Effertz 2009).

- Zustandsunsicherheit:** Zufällige Messfehler und physikalisch bedingtes Messrauschen führen auch zu Unsicherheiten in der Zustandsschätzung der Objekthypothesen. So detektieren z. B. Entfernungsmessungen auf Grund des Messrauschens unvermeidlich eine im Vergleich zur wahren Entfernung größere oder kleinere Distanz. Dies führt zu einer Unsicherheit in der Entfernungsschätzung. Ferner führen Fehler in den Modellbildungen zu Unsicherheiten in der Zustandsschätzung (Prozessunsicherheit). Diese treten auf, wenn z. B. das zur Modellierung der Objektbewegung eingesetzte Dynamikmodell nicht mit der tatsächlichen Bewegung des Objektes übereinstimmt.
- Assoziationsunsicherheit:** Zuordnungsfehler zwischen Objekthypothesen und Messungen führen zu einer Unsicherheit in der Assoziation. Zwei Arten von Fehlern sind hierbei möglich: Eine Messung wird fälschlicherweise nicht der zugehörigen Objekthypothese zugeordnet oder eine Messung wird fälschlicherweise einer anderen als der verursachenden Objekthypothese zugeordnet. Fehler bei der Assoziation verletzen die Annahmen der meisten Filter-Verfahren und wirken sich daher stark auf die Qualität des maschinell erstellten Umfeldmodells aus.

Nach DIN ISO 5725-1:1994 werden im Kontext von Messverfahren- und ergebnissen folgende für diese Arbeit relevante Begriffe verwendet:

- **Präzision:** Beschreibt die Streuung der Messwerte, ist aber unabhängig von der Entfernung der Messwerte zum wahren Wert (zufällige Abweichungskomponente).
- **Richtigkeit:** Beschreibt, wie nahe die gemittelten Messwerte einer großen Stichprobe beim wahren Wert (bzw. der Referenz) liegen (systematische Abweichungskomponente).
- **Genauigkeit:** Eine hohe Genauigkeit liegt vor, wenn sowohl eine hohe Präzision als auch eine hohe Richtigkeit festgestellt werden kann.

2.2.2 Laserscanner

Die Lidar-Technologie (**L**ight **D**etection and **R**anging) hat in der Automotive-Forschung zuletzt weite Verbreitung gefunden (vgl. Klose 2008, Rauskolb u. a. 2008, Darms 2008, Leonard u. a. 2008, Petrovskaya u. Thrun 2008, Effertz 2009 und Wille u. a. 2010). Lidar-Systeme verwenden in der Regel Laserimpulse im nicht-sichtbaren Infrarotspektrum (ca. 900nm) (vgl. Skutec 2006, Boehlau u. a. 2009). Die Systeme basieren in der Regel auf der sogenannten Lidar-Laufzeit-Messung. Hierbei wird ein Laserpuls von einer Sendeeinheit ausgesendet. Die von einem Objekt zurückgestreuten Pulse werden durch eine Empfangseinheit ausgewertet. Eine schematische Darstellung des durch die Empfangseinheit detektierten Rückstreusignals zeigt Abbildung 2.5. Das Rückstreusignal enthält neben der Streuung an einem Objekt auch noch die Streuung an der Abschlusscheibe. Diese wird z. B. bei dem Laserscanner Hella IDIS 2.0 als Basis für die Laufzeit- und damit für die Entfernungsschätzung genutzt (vgl. Boehlau u. a. 2009). Die bei Laserscannern eingesetzte Rohsignalverarbeitung bildet nicht den Schwerpunkt dieser Arbeit, daher werden die Grundideen im Folgenden nur kurz beschrieben: Das Signal wird zunächst diskretisiert. Anschließend wird aus der Auswertung der Laufzeit, in Relation zur bekannten Lichtgeschwindigkeit, die Entfernung des Objektes bestimmt. Hierbei ergibt sich die Entfernung r in Abhängigkeit von der Laufzeit des Lichtes t_l und Ausbreitungsgeschwindigkeit des Lichtes c wie folgt:

$$r = \frac{c * t_l}{2} \quad (2.1)$$

Die Messung eines Laserscanners besteht üblicherweise aus einer Entfernung r und einem Winkel ϕ in einem Polarkoordinatensystem. Je nach Art des Sensors gibt es noch zusätz-




Bild 2.5: Schematische Darstellung des diskretisierten Rückstreusignals eines Laserscanners und der aus der bekannten Lichtgeschwindigkeit resultierenden Entfernungsschätzung.

liche Informationen z. B. über die Intensität des reflektierten Pulses (Amplitude a). Der Vorteil eines Lidar-Systems liegt in der Praxis unter anderem in der im Vergleich zu Radar-Systemen besseren Winkelauflösung. Überdies liefern Lidar-Systeme, im Gegensatz zu Radarsensoren, Informationen über die Kontur eines Objektes. In das Fahrzeug-Design integrierte Lidar-Systeme erreichen im Automotive-Umfeld eine Reichweite von ca. 200m und einen Öffnungswinkel von maximal 180°. Nachteilig ist die eingeschränkte Leistungsfähigkeit bei schlechtem Wetter. Vor allem bei Gicht und Nebel ist die maximale Reichweite von Lasersensoren eingeschränkt. Außerdem ist das Geschwindigkeitssignal, welches z. B. bei Radar-Sensoren über den Doppler-Effekt direkt gemessen wird, bei den häufig verwendeten Lidar-Laufzeit-Systemen nur indirekt, z. B. über die Differentiation des Abstandssignals, bestimmbar. Weiterhin kommt es, je nach Betrachtungswinkel, zu Totalreflexion von Laserpulsen an Oberflächen. Objekte sind unter diesen Bedingungen für einen Laserscanner nahezu unsichtbar.

Ein Lidar-Sensor besteht aus mindestens einem Laser als Sender und mindestens einer Empfangsdiode. Bei der Lidar-Technologie wird zwischen Multi-Beam-Lasern und Laserscannern unterschieden. Bei Multi-Beam-Lasern gibt es im Allgemeinen für jeden Kanal einen Sender und eine Empfangseinheit. Multi-Beam-Laser haben in der Praxis mit z. B. 16° einen eingeschränkten Winkelbereich und sind daher für den Einsatz im Kreuzungsbereich ungeeignet. Beim Laserscanner gibt es oft nur eine Sende- und eine Empfangseinheit, die über das scannende Prinzip einen großen Bereich abtastet. Der mechanische Aufbau der Laserscanner ist auf Grund des scannenden Prinzips aufwändiger als der des Multi-Beam-Lasers. Dafür ist es theoretisch möglich, mit einem Laserscanner einen Winkelbereich von 360° abzudecken. *Seriennahe Laserscanner* erreichen auf Grund von Einschränkungen bei

der Fahrzeugintegration einen Öffnungswinkel von nahezu 180° und sind daher für den Einsatz im Kreuzungsbereich geeignet. Zu unterscheiden sind Einebenen-Laserscanner mit einer vertikalen Winkelauflösung von z. B. 3° und Mehrebenen-Laserscanner mit z. B. vier Ebenen mit einer vertikalen Winkelauflösung von jeweils $0,25^\circ$. Im Rahmen dieser Arbeit wird der Lidar-Laufzeit-Scanner IDIS 2.0 der Firma Hella für die experimentelle Validierung der Algorithmen verwendet (vgl. Boehlau u. a. 2009). Dieser verfügt über einen horizontalen Winkelbereich von 161° unterteilt in 161 Kanäle mit je 1° Öffnungswinkel. Der vertikale Öffnungswinkel dieses Einebenen-Laserscanners beträgt 3° .

Genauigkeit der radialen Positionsschätzung

Die *Präzision* (mittlere Streuung bei mehreren Messungen eines stationären Zieles) des verwendeten Laserscanners wird mit $\pm 0,1\text{m}$ angegeben, die *Richtigkeit* mit $\pm 0,5\text{m}$ (vgl. Boehlau u. a. 2009). Letztere ($\frac{\Delta r}{2} = 0,47\text{m}$) resultiert aus der in Abbildung 2.5 schematisch dargestellten Diskretisierung des Rückstreusignals mittels eines A/D-Wandlers und einer Frequenz von 160MHz .

$$\Delta r = \frac{c * \Delta t_l}{2} \quad (2.2)$$

$$= \frac{c}{2} * \frac{1}{160\text{MHz}} \quad (2.3)$$

$$= 0,9375\text{m} \quad (2.4)$$

Tests im Rahmen des Projekts Intersafe2 ergaben bei einem dynamischen Objekt einen mittleren Fehler von nahezu 0m bei der radialen Entfernungsschätzung. Die Standardabweichung ist hierbei $0,5\text{m}$ (INT 2011).

Genauigkeit der horizontalen Positionsschätzung

Nach Kämpchen (2007) ist die *horizontale Positionsschätzung* eines mit einem Laserscanner vermessenen Objektes mit Unsicherheiten behaftet (wie z. B. in der in Abbildung 2.6 beschriebenen Situation). Dies resultiert aus der diskreten Winkelauflösung ($\Delta\alpha$) und dem Kanalöffnungswinkel (β) des Laserscanners. Unter Berücksichtigung der radialen Entfernung ergibt sich daraus die Genauigkeit der horizontalen Positionsschätzung. In der in Abbildung 2.6 dargestellten Situation wird ein Objekt von vier Laserstrahlen vermessen. Zu sehen ist, dass die Strahlen nicht exakt die tatsächliche Kontur des Objektes beschreiben. Der Bias der Winkelmessung ergibt sich wie folgt, hierbei ist $\lambda \in [0, 1]$ die Überlappung zwischen Strahl




Bild 2.6: Schematische Darstellung der Detektion eines Objektes in vier Kanälen und der daraus resultierenden Unsicherheit in der lateralen Positionsschätzung.

und Fahrzeug (Herleitung: vgl. Kämpchen 2007):

$$\mu_{\alpha}(\Delta\alpha, \beta, \lambda = 0, 5) = \frac{1}{2}\Delta\alpha \quad (2.5)$$

Die Varianz der Winkelmessung ergibt sich zu (Herleitung: vgl. Kämpchen 2007):

$$\sigma_{\alpha}^2(\Delta\alpha, \beta, \lambda) = \frac{1}{12}\Delta\alpha^2 \quad (2.6)$$

Beide Fehler sind also von der Winkelauflösung des Laserscanners ($\Delta\alpha$) abhängig.

Erhöhung der Unsicherheit der radialen Entfernungsschätzung durch Kantenfehler und den Aspektwinkel

Durch die aus dem vertikalen Öffnungswinkel von $\varphi = 3^\circ$ und dem horizontalen Öffnungswinkel von 1° resultierende flächige Ausbreitung des Laserstrahls treten bei Reflexionen an Objekten Messunsicherheiten in der Entfernung r auf. Die Messunsicherheit schwankt daher in Abhängigkeit von der Perspektive (Aspektwinkel α) und der Entfernung r . Dieser Effekt tritt aufgrund der flächigen Strahlausbreitung in zwei Dimensionen, nämlich sowohl in der Horizontalen als auch in der Vertikalen, auf. Der Zusammenhang ist in Abbildung 2.7 beispielhaft für eine Dimension dargestellt. Die Unsicherheit entsteht, da die Messung auf Grund der Strahlaufweitung keinerlei Rückschluss über die tatsächliche Lage des Reflexionszentrums innerhalb des Strahls zulässt. Dies tritt hauptsächlich auf, wenn die Objektkante nicht orthogonal zur Strahlrichtung ausgerichtet ist. So könnte sich in Abbildung 2.7 an dem mit r gekennzeichneten Rand des Sensorkegels ein dominanter Retroreflektor befinden.




Bild 2.7: Schematische Darstellung des Aspektwinkels bei der Beobachtung eines Objektes, das nicht orthogonal zur Strahlrichtung orientiert ist.

Genauso könnte das Reflexionszentrum im Extremfall aber auch an der anderen Seite des Sensorkegels liegen. Diese Unsicherheit lässt sich mathematisch wie folgt beschreiben:

$$\sigma_r = 2 \cdot r \cdot \sin\left(\frac{\varphi}{2}\right) * \frac{\sin(\alpha)}{\sin\left(\frac{\pi}{2} - \varphi - \frac{\varphi}{2} - \alpha\right)} \quad (2.7)$$

wenn $\alpha \gg \varphi$ vereinfacht sich dies näherungsweise zu:

$$\sigma_r \approx 2 \cdot r \cdot \sin\left(\frac{\varphi}{2}\right) \cdot \tan(\alpha) \quad (2.8)$$

mit: Aspektwinkel α , Entfernung r und dem vertikalen Kanalöffnungswinkel φ . Weitere Quellen von Messunsicherheiten sind Sprünge oder Kanten in der vermessenen Objektkontur, diese Zusammenhänge werden z. B. in Stahn (2010) detailliert untersucht.

2.2.3 Partikelfilter

Das Partikelfilter ist ein bekanntes und im Bereich der Robotik häufig verwendetes Filter zur Zustandsschätzung linearer und nichtlinearer Systeme. Die Wahrscheinlichkeitsdichtefunktion wird bei den Partikelfiltern durch N_S Zustandsvektoren (gewichtete Partikel) approximiert (vgl. Isard u. Blake 1998 und Ristic u. a. 2004). Auf jedes Partikel werden hierbei unterschiedliche Objekt- und Dynamikmodelle angewendet. Daher hat dieses Verfahren den *Vorteil*, dass es keinerlei Einschränkungen bezüglich der Verwendung nichtlinearer Modelle unterliegt. Jedes Partikel repräsentiert hierbei eine Hypothese des Objektzustandes. Das Partikelfilter arbeitet rekursiv, in einem ersten Schritt werden die Partikel auf einen neuen Messzeitpunkt prädiert, und in einem zweiten Schritt werden die jeweiligen Gewichte der Partikel angepasst. Dieses Vorgehen wird als Sequential Importance Sampling (SIS) bezeichnet und bildet die Grundlagen vieler Partikelfilter.

Zu beachten ist bei den Partikelfiltern, dass die Anzahl der Partikel (N_S) mit wachsender Nichtlinearität und zunehmender Dimensionalität des Zustandsvektors stark ansteigt. Der *Rechenaufwand* ist gerade bei multidimensionalen Zustandsräumen sehr hoch (vgl. Hoffmann 2007). Lindl (2008) zeigt, dass für die stabile Verfolgung von Fahrzeugen mittels eines Laserscanners 400-800 Partikel pro Objekthypothese notwendig sind und kommt daher zu dem Schluss, dass Partikelfilter für die Multiobjektverfolgung von Fahrzeugen nach aktuellem Stand der Technik nicht echtzeitfähig sind. Auf die Verwendung von Partikelfiltern wird daher im Rahmen dieser Arbeit verzichtet.

2.2.4 Kalman-Filter

Das Kalman-Filter ist seit 1960 (vgl. Kalman 1960) ein bekanntes und im Bereich der maschinellen Umfeldwahrnehmung in der Automobilindustrie häufig verwendetes Filter zur *Zustandsschätzung*. Ziel ist die Schätzung des Mittelwertes $\hat{\mathbf{x}}(k)$ und der zugehörigen Kovarianzmatrix $\mathbf{P}(k)$ des Zustandes aus einer Messreihe $\mathbf{z}(k)$. Der grundlegende Ablauf des Kalman-Filters basiert auf folgenden drei Schritten:

- **Prädiktion:** Im ersten Schritt wird die aktuelle Zustandshypothese auf einen zukünftigen Zeitpunkt prädictiert. Hierfür werden die Historie und physikalische Gesetzmäßigkeiten genutzt. Letztgenannte werden in sogenannten Dynamikmodellen abgebildet.
- **Assoziation:** In einem zweiten Schritt stellt die Assoziation einen Zusammenhang zwischen einer Beobachtung (Messung) und einer prädictierten Objekthypothese (Prädiktion) her.
- **Innovation/Korrektur:** Im dritten Schritt wird eine neue Zustandshypothese anhand der Differenz aus Prädiktion und Messung geschätzt.

Da es die Grundlage der in dieser Arbeit vorgestellten Ansätze bildet, wird die Funktionsweise des diskreten Kalman-Filters mit konstanter Abtastzeit T im Folgenden detaillierter beschrieben. Hierbei sei $\hat{\mathbf{x}}(k) := \hat{\mathbf{x}}(t_k)$ und $\mathbf{z}(k) := \mathbf{z}(t_k)$, mit $t_k = t_0 + k \cdot T$. Mit Hilfe des Dynamikmodells werden die einzelnen Wahrscheinlichkeitsverteilungen prädictiert und durch das Prozessrauschen überlagert ($\mathbf{P}_{pre}(\hat{\mathbf{x}}_{pre}(k)|\mathbf{z}(k))$). Im Innovationsschritt werden die prädictierten Wahrscheinlichkeitsverteilungen durch die eingebrachten Messungen ($\mathbf{z}(k+1)$) korrigiert ($\mathbf{P}(\hat{\mathbf{x}}(k+1)|\mathbf{z}(k+1))$).

Beim Kalman-Filter ist die *Modellbildung* von wesentlicher Bedeutung. Modelle werden benötigt, um stochastische Messfehler und unvermeidliches, physikalisch bedingtes Messrauschen zu kompensieren. Im Falle eines linearen Dynamikmodells, weißer Rauschgrößen und

einer linearen Messfunktion bildet das Kalman-Filter eine optimale Lösung oben genannter Problemstellung. Die physikalischen Eigenschaften der Messung werden mit einem Messmodell und einem zusätzlichen additiven Messrauschen modelliert. Das Filter ist optimal, wenn Initialisierungsfehler und die verschiedenen Rauschterme unkorreliert und weiß sind. Für die mathematische Beschreibung des diskreten Kalman-Filters (Bar-Shalom u. a. 2001, S. 200 ff.) ergibt sich daraus Folgendes:

Zu jedem Zeitpunkt k sei die Historie in der Zustandshypothese $\hat{\mathbf{x}}(k)$ und der Kovarianzmatrix $\mathbf{P}(k)$ abgebildet. Im Prädiktionsschritt wird die prädizierte Zustandshypothese $\hat{\mathbf{x}}_{pre}$ und die zugehörige prädizierte Kovarianzmatrix \mathbf{P}_{pre} berechnet. $\hat{\mathbf{x}}_{pre}$ ergibt sich aus der Multiplikation der Zustandsmatrix \mathbf{F} mit dem aktuellen Zustand $\hat{\mathbf{x}}$ unter Berücksichtigung des Prozessrauschens \mathbf{v} (hierbei sei $E[\mathbf{v}] = 0, E[\mathbf{v}, \mathbf{v}'] = \mathbf{Q}$ und \mathbf{v} somit erwartungswertfrei mit der Prozesskovarianzmatrix \mathbf{Q}):

$$\hat{\mathbf{x}}_{pre}(k+1|k) = \mathbf{F} \cdot \hat{\mathbf{x}}(k|k) + \mathbf{v} \quad (2.9)$$

Der Zustandshypothesenvektor $\hat{\mathbf{x}}$ besteht hierbei beispielsweise aus folgenden Komponenten (x, y - Position, v_x, v_y - Geschwindigkeit und d - Durchmesser (zeitlich konstanter Parameter, vgl. Abschnitt 4.2)):

$$\hat{\mathbf{x}} = \begin{pmatrix} x \\ y \\ v_x \\ v_y \\ d \end{pmatrix} \quad (2.10)$$

Die Zustandsmatrix $\mathbf{F}(T)$ beschreibt das Modell für die Veränderung der Zustandshypothese zwischen zwei Zeitschritten. Üblich ist hier z. B. die Annahme der Fortsetzung der bisherigen Bewegung mit gleicher Geschwindigkeit (konstantes Geschwindigkeitsmodell), T sei hierbei die Zykluszeit des Sensors. Für das Bewegungsmodell gelten hierbei folgende Gleichungen:

$$x_{pre}(k+1|k) = x(k|k) + T \cdot v_x(k|k) \quad (2.11)$$

$$y_{pre}(k+1|k) = y(k|k) + T \cdot v_y(k|k) \quad (2.12)$$

$$v_{x,pre}(k+1|k) = v_x(k|k) \quad (2.13)$$

$$v_{y,pre}(k+1|k) = v_y(k|k) \quad (2.14)$$

$$d_{pre}(k+1|k) = d(k|k) \quad (2.15)$$

Daraus ergibt sich für die Zustandsmatrix $\mathbf{F}(T)$:

$$\mathbf{F}(T) = \begin{pmatrix} 1 & 0 & T & 0 & 0 \\ 0 & 1 & 0 & T & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix} \quad (2.16)$$

Im Folgenden sei die Abtastzeit T als konstant angenommen, die Zustandsmatrix $\mathbf{F}(T)$ wird daher als unveränderlich angenommen und als Zustandsmatrix \mathbf{F} bezeichnet. Die Modellunsicherheit des Modells mit konstanter Geschwindigkeit wird mit der Prozesskovarianzmatrix $\mathbf{Q}(T)$, vereinfacht als \mathbf{Q} bezeichnet beschrieben:

$$\mathbf{Q} = \begin{pmatrix} \frac{1}{4}T^4\sigma_{ax}^2 & 0 & \frac{1}{2}T^3\sigma_{ax}^2 & 0 & 0 \\ 0 & \frac{1}{4}T^4\sigma_{ay}^2 & 0 & \frac{1}{2}T^3\sigma_{ay}^2 & 0 \\ \frac{1}{2}T^3\sigma_{ax}^2 & 0 & T^2\sigma_{ax}^2 & 0 & 0 \\ 0 & \frac{1}{2}T^3\sigma_{ay}^2 & 0 & T^2\sigma_{ay}^2 & 0 \\ 0 & 0 & 0 & 0 & T^2\sigma_d^2 \end{pmatrix} \quad (2.17)$$

Der für diese Prädiktion erwartete Fehler (Kovarianzmatrix \mathbf{P}_{pre}) ergibt sich aus der Multiplikation mit der Zustandsmatrix \mathbf{F} zuzüglich der Addition mit der Modellunsicherheit (Prozesskovarianzmatrix \mathbf{Q}):

$$\mathbf{P}_{pre}(k+1|k) = \mathbf{F} \cdot \mathbf{P}(k|k) \cdot \mathbf{F}^T + \mathbf{Q} \quad (2.18)$$

der Messvektor \mathbf{z} sei im Folgenden beispielhaft definiert:

$$\mathbf{z} = \begin{pmatrix} x \\ y \\ d \end{pmatrix} \quad (2.19)$$

Somit ergibt sich folgender Zusammenhang zwischen Zustandsraum und Messraum, dieser wird in der Messmatrix \mathbf{H} beschrieben:

$$\mathbf{H} = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix} \quad (2.20)$$

Unter Berücksichtigung des Messrauschens \mathbf{w} (hierbei sei $E[\mathbf{w}] = 0$, $E[\mathbf{w}, \mathbf{w}'] = \mathbf{R}$ und \mathbf{w} somit erwartungswertfrei mit der Messkovarianzmatrix \mathbf{R}) beschreibt die Messmatrix \mathbf{H} die Abhängigkeit zwischen dem Zustandshypothesenvektor $\hat{\mathbf{x}}_{pre}$ und dem Messhypothesenvektor $\hat{\mathbf{z}}_{pre}$. Dieser Zusammenhang wird auch als Sensormodell bezeichnet:

$$\hat{\mathbf{z}}_{pre}(k+1|k) = \mathbf{H} \cdot \hat{\mathbf{x}}_{pre}(k+1|k) + \mathbf{w} \quad (2.21)$$

Die Unsicherheiten der Messung sind dabei wie folgt in der Messkovarianzmatrix \mathbf{R} beschrieben:

$$\mathbf{R} = \begin{pmatrix} \sigma_x^2 & 0 & 0 \\ 0 & \sigma_y^2 & 0 \\ 0 & 0 & \sigma_d^2 \end{pmatrix} \quad (2.22)$$

Dies ergibt die Schätzung der zugehörigen Kovarianzmatrix \mathbf{P}_{pre} unter der Annahme, der in Messkovarianzmatrix \mathbf{R} beschriebenen Messunsicherheiten. Hierbei sei \mathbf{S} die Innovationskovarianzmatrix und \mathbf{W} die Kalman-Filtermatrix:

$$\mathbf{S}(k+1) = \mathbf{H} \cdot \mathbf{P}_{pre}(k+1|k) \cdot \mathbf{H}^T + \mathbf{R} \quad (2.23)$$

$$\mathbf{W}(k+1|k) = \mathbf{P}_{pre}(k+1|k) \cdot \mathbf{H}^T \cdot (\mathbf{S}^{-1}(k+1)) \quad (2.24)$$

$$\mathbf{P}(k+1|k+1) = \mathbf{P}_{pre}(k+1|k) - \mathbf{W}(k+1|k) \cdot \mathbf{S}(k+1) \cdot \mathbf{W}(k+1|k)^T \quad (2.25)$$

Abschließend wird die aktuelle Zustandshypothese $\hat{\mathbf{x}}$ im Korrektorschritt geschätzt, $\nu(k+1)$ sei hierbei der Innovationsvektor:

$$\nu(k+1) = \mathbf{z}(k+1) - \mathbf{z}_{pre}(k+1|k) \quad (2.26)$$

$$\hat{\mathbf{x}}(k+1|k+1) = \hat{\mathbf{x}}_{pre}(k+1|k) + \mathbf{W}(k+1|k) \cdot \nu(k+1) \quad (2.27)$$

Das Kalman-Filter verlangt, dass die Dynamik- und die Sensormodelle *linear* sind. Diese Bedingung ist jedoch in der Praxis häufig nicht erfüllt. Sowohl die Dynamikmodelle, wie z. B. Modelle für Kurvenfahrten, als auch die Transformation der in Polarkoordinaten gemessenen Sensordaten weisen Nichtlinearitäten auf. Die Berücksichtigung von Nichtlinearitäten führen zu Erweiterungen des Kalman-Filters. Dies sind das Extended-Kalman-Filter (EKF) und das Unconstrained-Kalman-Filter (UKF). Hierbei werden die nichtlinearen Funktionen um den Schätzwert *linearisiert*. Das EKF beruht auf einer Taylor-Näherung 1. Ordnung wohingegen das UKF auf einem Modell der Fehlerfortpflanzung basiert, das die Kovarianzmatrix und den Mittelwert bis zur dritten Stufe der Taylor-Reihe approximiert. Das EKF ist komplizierter

zu implementieren als das UKF, da beim EKF die Jacobi-Matrizen zur Bestimmung der 1. Taylor-Näherung berechnet werden. Dies resultiert in einer etwas geringeren Richtigkeit der Ergebnisse des EKF im Vergleich mit dem UKF im Falle starker Nichtlinearität. Dafür ist der Rechenaufwand des EKF geringer als der des UKF (vgl. Lindl 2008). Lindl (2008) zeigt, dass das UKF dem EKF in der Schätzgenauigkeit für die im Automobilbereich relevanten Szenarien nur minimal überlegen ist. Die für die Berechnung benötigte Zeit verdoppelt sich jedoch. Da die Echtzeitfähigkeit trotz einer Vielzahl von Objekthypothesen vorausgesetzt wird, wird im weiteren Verlauf dieser Arbeit das Extended-Kalman-Filter als Kompromiss zwischen Schätzgenauigkeit und Rechenaufwand verwendet.

Beim EKF wird die Zustandsübergangsmatrix \mathbf{F} um den Zustand $\hat{\mathbf{x}}(k)$ linearisiert. Die Messmatrix \mathbf{H} ergibt sich aus der Linearisierung um den prädictierten Zustand $\hat{\mathbf{x}}_{pre}(k|k-1)$:

$$\hat{\mathbf{x}}_{pre}(k+1|k) = f[k, \hat{\mathbf{x}}(k|k)] \quad (2.28)$$

$$\mathbf{z}_{pre}(k+1|k) = h[k+1, \hat{\mathbf{x}}_{pre}(k+1|k)] \quad (2.29)$$

Hierfür wird die Jacobi-Matrix \mathbf{J}_f gebildet. Dabei seien $\hat{\mathbf{x}} = (x_1, x_2, \dots, x_n)$ die Koordinaten im Urbildraum und f_1, f_2, \dots, f_n die Komponentenfunktionen:

$$\mathbf{J}_f = \begin{pmatrix} \frac{\partial f_1}{\partial x_1} & \frac{\partial f_1}{\partial x_2} & \dots & \frac{\partial f_1}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial f_n}{\partial x_1} & \frac{\partial f_n}{\partial x_2} & \dots & \frac{\partial f_n}{\partial x_n} \end{pmatrix} = \begin{pmatrix} \nabla f_1^T \\ \vdots \\ \nabla f_n^T \end{pmatrix} \quad (2.30)$$

Mittels der Hesse-Matrix \mathbf{H}_f (2. Ableitung einer Vektorfunktion) ist auch eine Linearisierung 2. Ordnung möglich. Bei der Näherung des Extended-Kalman-Filters sind nach Stüker (2004) zwei Fehlerquellen zu beachten:

1. Truncation Error: Es wird nur die erste Ableitung berücksichtigt, Terme höherer Ordnung werden vernachlässigt.
2. Base Point Error: Die Linearisierung erfolgt um den Schätzwert und nicht um den wahren Wert. Die Linearisierung enthält daher Schätzfehler.

Im Kontext dieser Arbeit wird ein Kalman-Filter zur Zustandsschätzung genutzt. Auf Grund von Nichtlinearitäten wird eine Erweiterung des Kalman-Filters verwendet. Da die Echtzeitfähigkeit gerade bei einer Vielzahl von Objekthypothesen gefordert wird, ist das Extended-Kalman-Filter ein geeigneter Kompromiss zwischen Schätzgenauigkeit und Rechenaufwand.

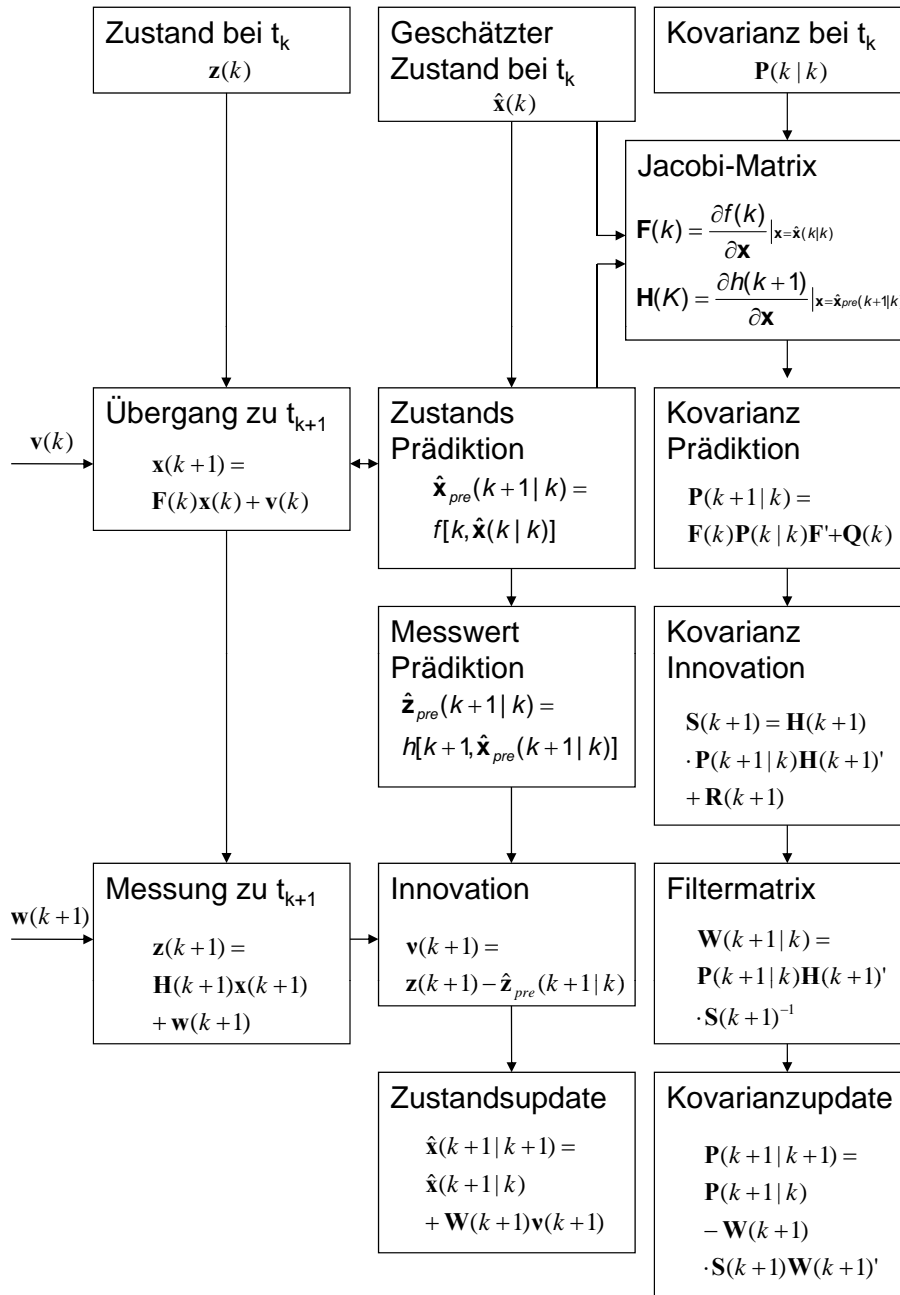


Bild 2.8: Flussdiagramm des Extended-Kalman-Filters (1. Ordnung) nach Bar-Shalom u. Li (1993)

2.2.5 Interacting-Multi-Model-Filter zur Multiobjektverfolgung

Multi-Modell-Filter bestehen aus *mehreren, parallel arbeitenden Filtern* mit Optimierungen für unterschiedliche Bewegungsmodelle. Sie lösen damit das in der automobilen Umfeldwahrnehmung häufig auftretende Problem, dass unimodale Filter mit nur einem Bewegungsmodell *wechselnde dynamische Bewegungen* prinzipbedingt nur unzureichend abbilden. Es werden drei Arten von Multi-Modell-Schätzern unterschieden (vgl. Bar-Shalom u. a. 2001, S. 421 ff.). Diese unterscheiden sich in den Algorithmen der Interaktion der einzelnen Filter. Eine optimale Interaktion ist auf Grund der mit jedem Zeitschritt exponentiell steigenden Kombinationsmöglichkeiten und des damit einhergehenden Rechenaufwandes nicht echtzeitfähig. Daher haben sich sogenannte suboptimale Verfahren etabliert. Diese verwerfen gezielt Kombinationsmöglichkeiten aus der Vergangenheit und sind daher echtzeitfähig:

- **Static-Multiple-Model-Filter (SMM):** Bei dieser Filtergattung findet keine Interaktion zwischen den verschiedenen Filtern statt. Jedes Filter nutzt seinen letzten Zustand für eine neue Iteration. Das Filter konvergiert mit der Zeit gegen jenes Filter, das dem tatsächlichen Modus am nächsten kommt.
- **Generalized-Pseudo-Baysian-Filter (GPB):** Dieses Filter betrachtet nur die Übergänge des letzten Zeitschritts. Alle Filter werden zu einem einzigen Zustand kombiniert. Dieser Zustand bildet die Basis aller Filter für eine neue Iteration.
- **Interacting-Multi-Model-Filter (IMM):** Bei dieser Filtergattung wird der Übergang zwischen den verschiedenen Filtern als Markov-Kette modelliert. In jedem Filterschritt wird für jedes Modell ein neuer Zustand aus der Kombination der Zustände aller Filter gebildet. Jedes Filter geht also mit einem kombinierten Zustand in die nächste Iteration.

Bar-Shalom u. a. (2001, S. 421 ff.) zeigen, dass das IMM-Filter eine effiziente Form zur Verringerung der Interaktionsmöglichkeiten darstellt, die Modelle interagieren hierbei über Modellwahrscheinlichkeiten miteinander. Die Entscheidung, welches Bewegungsmodell zur aktuell beobachteten Objekthypothese passt, wird auf spätere Messzyklen vertagt. Der Rechenaufwand steigt hierbei linear mit der Anzahl der betrachteten Modelle. Algorithmisch liegt dem IMM der im Folgenden beschriebene Ablauf zu Grunde (vgl. Bar-Shalom u. a. 2001, S. 454). Zunächst wird die Übergangswahrscheinlichkeit $\mu_{ij}(k-1)$, dass sich die Objekthypothese in Zustand i befindet und in den Zustand j wechselt berechnet:

$$\mu_{ij}(k-1) = \frac{\mathbf{P}_{ij} \cdot \mu_i(k-1)}{C_j(k-1)} \quad (2.31)$$

mit

$$C_j(k-1) = \sum_{i=1}^r \mathbf{P}_{ij} \cdot \mu_i(k-1) \quad (2.32)$$

Daraus ergeben sich für die Interaktion der Zustandshypothesen (vgl. Bild 2.9) und der zugehörigen Kovarianzmatrizen für die nächste Iteration folgende Zusammenhänge:

$$\hat{\mathbf{x}}_j^0(k-1|k-1) = \sum_{i=1}^r \mu_{ij}(k-1) \cdot \hat{\mathbf{x}}_i(k-1|k-1) \quad (2.33)$$

$$\begin{aligned} \mathbf{P}_j^0(k-1|k-1) &= \sum_{i=1}^r \mu_{ij}(k-1) \cdot \{\mathbf{P}_i(k-1|k-1) \\ &\quad + [\hat{\mathbf{x}}_i(k-1|k-1) - \hat{\mathbf{x}}_j^0(k-1|k-1)] \\ &\quad \cdot [\hat{\mathbf{x}}_i(k-1|k-1) - \hat{\mathbf{x}}_j^0(k-1|k-1)]^T\} \end{aligned} \quad (2.34)$$

Die Zustandshypothese $\hat{\mathbf{x}}_j^0(k-1|k-1)$ und die zugehörige Zustandskovarianzmatrix $\mathbf{P}_j^0(k-1|k-1)$ werden auf den nächsten Zeitschritt prädiert ($\hat{\mathbf{x}}_{j,pre}^0(k|k-1)$ und $\mathbf{P}_{j,pre}^0(k|k-1)$). Anschließend wird der, aus dem klassischen Kalman-Filter, bekannte Schritt der Innovation durchlaufen. Die Modellwahrscheinlichkeiten μ_i berechnen sich dabei folgendermaßen:

$$\mu_i = \frac{\lambda_i(k) \cdot C_i(k-1)}{C} \quad (2.35)$$

$$(2.36)$$

mit

$$C = \sum_{j=1}^r \lambda_j(k) \cdot C_j(k-1) \quad (2.37)$$

$$\lambda_i(k) = \frac{\exp\left[\frac{-d_i^2(k)}{2}\right]}{\sqrt{(2 \cdot \pi)^M \cdot \det[\mathbf{S}_i(k)]}} \quad (2.38)$$

und

$$d^2 = \nu^T \cdot \mathbf{S}^{-1} \cdot \nu \quad (2.39)$$

$$\mathbf{S}(k) = \mathbf{H} \cdot \mathbf{P}(k|k-1) \cdot \mathbf{H}^T + \mathbf{R} \quad (2.40)$$

$$\nu(k) = \mathbf{z}(k) - \mathbf{H} \cdot \hat{\mathbf{x}}(k|k-1) \quad (2.41)$$

hierbei sei

$\hat{\mathbf{x}}_i$ - Zustandshypothese im Modell i,

\mathbf{P}_i - Kovarianzmatrix im Modell i,

\mathbf{P}_{ij} - die a-priori zu bestimmende Übergangsmatrix von Modell i nach Modell j,

μ_i - Wahrscheinlichkeit, dass sich die Objekthypothese im Modell i befindet,

μ_{ij} - Übergangswahrscheinlichkeit, Wechsel vom Modell i in das Modell j.

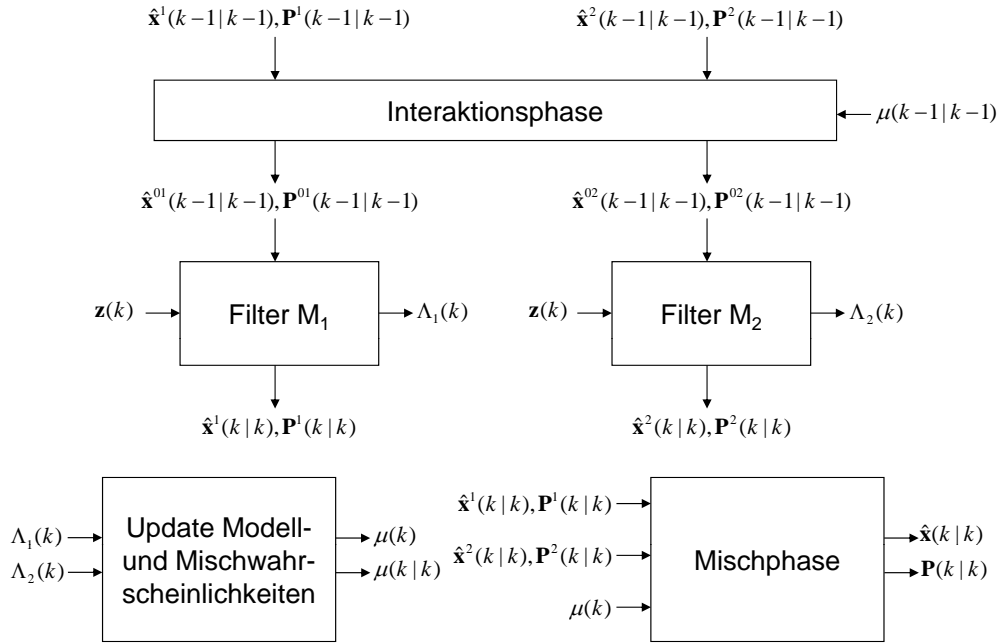


Bild 2.9: Flussdiagramm des Interacting-Multi-Model-Filters nach Bar-Shalom u. a. (2001, S. 454)

Zur Ausgabe werden die verschiedenen Zustände in der Mischphase zu einer Ausgabe-Zustandshypothese kombiniert (vgl. Bild 2.9). Diese Ausgabe-Zustandshypothese hat keinerlei Rückwirkungen auf folgende Zustandshypothesenschätzungen. Hierbei existieren zwei Möglichkeiten der Kombination: Ausgabe der Zustandshypothese mit der größten Modellwahrscheinlichkeit oder Ausgabe einer anhand der Modellwahrscheinlichkeiten aus allen Zustandshypothesen kombinierten Zustandshypothese. Das Interacting-Multi-Model-Filter wird in dieser Arbeit als Lösungsansatz für das häufig auftretende Problem, dass Filter mit nur einem Bewegungsmodell wechselnde dynamische Bewegungen prinzipbedingt nur unzureichend abbilden, verwendet. Das IMM-Filter verfügt im Vergleich zu den unimodalen Filtern über zwei zusätzliche a-priori (vgl. Bar-Shalom u. a. 2011, S. 28) zu bestimmende Parameter: Die Auswahl der Modelle und \mathbf{P}_{ij} - die Übergangsmatrix von Modell i nach Modell j.

2.3 Stand der Technik: Maschinelle Umfeldwahrnehmung in urbaner Umgebung

Basis aller in Kapitel 2.1 vorgestellten Fahrerassistenzsysteme und Forschungsaktivitäten zur Verringerung der Unfallzahlen in komplexen urbanen Szenarien ist eine maschinelle Umfeldwahrnehmung. Hierbei spielt die im Fahrzeug integrierte Sensorik neben anderen Informationsquellen eine zentrale Rolle. Dieses Kapitel beschreibt den Stand der Technik zum Objekttracking in urbanen Kreuzungsbereichen. Bild 2.10 zeigt, wie die verschiedenen Argumentationsstränge in Abschnitt 2.3.5 zusammengefasst werden.




Bild 2.10: Grafische Darstellung der Gliederung von Kapitel 2.3

2.3.1 Erweiterungen des Interacting-Multi-Model-Filters (IMM)

Zahlreiche Arbeiten widmen sich der Wahl der zusätzlichen Design-Parameter des Interacting-Multi-Model-Filters (IMM). Diese beschäftigen sich mit der A-Priori-Wahl und der Online-Anpassung der Übergangsmatrix und der Modellsätze und werden im Folgenden beschrieben:

A-priori-Adaption der Übergangsmatrix über einen Szenarienkatalog

Schäfer (2003), Kämpchen u. a. (2004), Weiß, K. (2006) und Kämpchen (2007) beschreiben einen Ansatz zur Nutzung eines IMM-Filters in hochdynamischen Stop & Go-Szenarien. Hierbei wird auf die Parametrisierung des IMM-Filters eingegangen (vgl. Schäfer 2003). Im Fokus steht die Auswahl der eingesetzten Modelle, wofür ein Signifikanztest durchgeführt wird. Ziel dieses Tests ist es, anhand eines a-priori bekannten Satzes von Beispielszenarien eine Auswahl von Modellen zu finden, die möglichst unterschiedlich sind. Dies verhindert Mehrdeutigkeiten und steigert so die Qualität der Objekthypothesenverfolgung. Die Übergangsmatrix wird in diesem Beitrag aus einer Auswertung der a-priori bekannten Szenarien und der darin enthaltenen Modellwechsel bestimmt. Zwei Ansätze zur verbesserten Initialisierung bei der Verwendung von Sensoren, die nicht direkt die Geschwindigkeit messen (wie z. B. Laserscanner), beschreibt Weiß, K. (2006). Auf Autobahnszenarien wird eine Initia-

lisierung der Objekthypothesen mit der eigenen Geschwindigkeit vorgeschlagen, aber auch deren Grenzen in kritischen Situationen (Objekt steht und daher ergibt sich eine Notbrems-situation) aufgezeigt. Alternativ wird eine Multi-Modell-Initialisierung mit dem Generalized-Pseudo-Baysian-Filter (GPB) vorgeschlagen. Hierbei werden drei unterschiedliche Geschwindigkeits-hypothesen initialisiert. Nach den ersten beiden Messungen wird aus diesen anhand der Modellwahrscheinlichkeiten eine Zustandshypothese gebildet. Das GPB-Filter wird nach diesen zwei Messungen verworfen und nur die gemeinsame Zustandshypothese für die weiteren Filterschritte (mittels IMM) genutzt. Für meine Arbeit ist der Ansatz, die Übergangswahrscheinlichkeiten anhand eines vordefinierten Szenarienkatalogs zu bestimmen, relevant. Zudem wird eine verbesserte Objektdetektion durch die Initialisierung der Objekthypothese mit der eigenen Geschwindigkeit (Lösungsansatz für Autobahnszenarien) vorgeschlagen.

Adaptive Übergangsmatrix

Burlet u. a. (2006) beschreibt ein IMM-Filter zur Verfolgung von Fußgängern. Hierfür werden acht sternförmig angeordnete Bewegungsmodelle verwendet. Der vorgestellte Ansatz beschäftigt sich mit der Problematik, dass es a-priori nur schwer möglich ist, die Übergangswahrscheinlichkeiten zwischen den verschiedenen Modellen zu bestimmen. Daher wird folgendes Verfahren vorgestellt: Basierend auf den Messwerten, werden die der zuletzt bestimmten Trajektorie am nächsten gelegenen Modelle mit einem höheren Gewicht versehen. Gegenteiliges geschieht für die der Trajektorie abgewandten Modelle. Für meine Arbeit ist der Ansatz, die Übergangswahrscheinlichkeiten anhand des bisherigen Trajektorienverlaufs zu bestimmen, relevant. Vom aktuellen Bewegungsmodell abgewandte Bewegungsmodelle sind demnach unwahrscheinlicher als benachbarte.

IMM mit variabler Dynamikmodellauswahl

Zhang u. a. (2008) stellt ein auf Extended-Kalman-Filtern (EKF) basierendes IMM-Filter vor. Das in diesem Ansatz vorgestellte IMM-Filter verfügt hierbei über eine variable Struktur, die abhängig von Informationen über den Fahrbahnverlauf, die Modellauswahl zur Laufzeit beeinflusst. In diesem IMM-Filter werden nicht immer alle verfügbaren Modelle parallel genutzt. In Abhängigkeit vom Fahrbahnverlauf wird gezielt der Satz von Modellen ausgewählt, der am besten zur aktuellen Situation passt. So wird auf einer geraden Straße ein Satz von Modellen ohne ein Modell für eine Kurvenfahrt ausgewählt, dies ändert sich sobald der Straßenverlauf kurvig wird. Dies verringert den benötigten Rechenaufwand und verbessert die Güte der Zustandsschätzung. Relevant für meine Arbeit ist der Ansatz, den aktuellen Satz der Dynamikmodelle an die durch die Sensorik erkannte Situation anzupassen.

IMM mit Bayes'schem Netz zur Adaption der Übergangsmatrix

Schubert u. Wanielik (2009), Schubert u. Wanielik (2011) und Schubert (2011) stellen einen Ansatz zur globalen Adaption der Übergangsmatrix im IMM-Filter vor, hierfür wird ein Bayes'sches Netz genutzt, um mit Unsicherheiten behaftete Information abzubilden. Dies hat den Vorteil, dass zusätzliche Informationen verwendet werden, falls diese vorhanden sind. Ist keine zusätzliche Information vorhanden, funktioniert das IMM-Filter in seiner ursprünglichen Form. Diese Erweiterung wird Meta-Modell-Filter (MMF) genannt. Beispielhaft wird dies an der Erkennung von Fahrbahnmarkierungen (durchgezogen, unterbrochen) demonstriert. Aus diesen wird auf die Wahrscheinlichkeit eines Fahrstreifenwechsels im Kontext einer **Adaptive Cruise Control** Umgebung geschlossen. Hierbei werden drei Fälle adressiert: Fahrstreifenwechsel nach links, Fahrstreifenwechsel nach rechts und Fahrt geradeaus im bisherigen Fahrstreifen. Als Dynamikmodelle im IMM-Filter werden hierfür Modelle mit konstanter Gierrate und konstanter Beschleunigung verwendet. Das Dynamikmodell für den Fahrstreifenwechsel basiert auf der Annahme einer konstanten Gierrate. Als denkbare Erweiterungen des vorgestellten Ansatzes wird unter anderem die Möglichkeit der Berücksichtigung von Navigationskartendaten genannt. Der vorgestellte Ansatz stellt eine Erweiterung des klassischen IMM-Filters bezüglich der Nutzung zusätzlicher Informationen dar. Der zusätzliche Rechenaufwand des Ansatzes ist begrenzt und ermöglicht eine Berechnung in Echtzeit. Für diese Arbeit ist der Ansatz, die Übergangswahrscheinlichkeiten anhand eines Meta-Modell-Filters online an die Situation anzupassen, relevant. Hierfür wird ein Bayes'sches Netz vorgeschlagen, das die Anpassung anhand von Sensorinformationen durchführt.

Fazit: Erhöhte Wahrscheinlichkeit längs- und querdynamischer Manöver in Kreuzungsbereichen

Unimodale Ansätze, wie z. B. das Extended-Kalman-Filter, sind den in urbanen Kreuzungsbereichen häufig auftretenden Manövern mit *wechselnder Längs- und/oder Querdynamik* unter Berücksichtigung der aktuell durch Sensoren verfügbaren Qualität nicht gewachsen. Daher haben sich Ansätze auf Basis des IMM-Filters zur Lösung dieses Problems etabliert (vgl. Hautaniemi u. Saarinen 2001, Musicki u. a. 2004 und Burlet u. a. 2006). Problematisch bei den IMM-Filtern ist jedoch, dass eine einfache Erhöhung der Modellanzahl nicht zwangsläufig zu einer Verbesserung der Genauigkeit der Zustandsschätzung führt. Insbesondere die a-priori zu bestimmende Übergangsmatrix, die die Übergangswahrscheinlichkeiten zwischen den verschiedenen Modellen beschreibt, stellt eine große Herausforderung dar. Die Übergangswahrscheinlichkeiten zwischen den verschiedenen Modellen sind, je nach *Ort und Situation*, stark unterschiedlich und können a-priori nahezu unmöglich für jede erdenkliche Situation korrekt angegeben werden. So ist z. B. auf einer geraden Strecke ohne Abzweigung

ein Übergang in ein Abbiegemanöver äußerst unwahrscheinlich, direkt vor einer Kreuzung hingegen ist der Übergang in ein Abbiegemanöver wahrscheinlicher. Schäfer (2003), Kämpchen u. a. (2004), Weiß, K. (2006) und Kämpchen (2007) versuchen die Übergangsmatrix über einen a-priori bekannten Szenarienkatalog zu adaptieren. Zhang u. a. (2008) (vgl. Abschnitt 2.3.1) versucht das Problem durch eine gezielte Auswahl, an die Situation angepasster Sets von Dynamikmodellen zu lösen, ignoriert damit aber die Orts- und Situationsabhängigkeit der Übergangsmatrix.

Schubert u. Wanielik (2009) (vgl. Abschnitt 2.3.1) beeinflusst die problematische Wahl der Übergangsmatrix während der Laufzeit über ein Bayes'sches Netz. Hierfür wird ein Kamerasystem zur Erkennung der Fahrstreifenmarkierungen eingesetzt. Problematisch bei der Anwendung im urbanen Umfeld ist hierbei, dass aktuell kein seriennahes Kamerasystem zur Verfügung steht, das es ermöglicht, im Kreuzungsbereich mit ausreichender Reichweite und mit ausreichendem Öffnungswinkel Fahrstreifenmarkierungen zu detektieren. Zugleich adaptiert das in Schubert u. Wanielik (2009) vorgestellte Meta-Modell-Filter eine gemeinsame Übergangsmatrix für alle Objekthypothesen. Dieses Vorgehen stößt in urbanen Kreuzungsszenarien jedoch an Grenzen. So ist es zum Beispiel denkbar, dass eine Objekthypothese kurz vor einer Kreuzung nur die Möglichkeit hat geradeaus zu fahren, demnach ist ein Übergang in eines der Abbiegemodelle unwahrscheinlich. Im gleichen Augenblick befindet sich eine weitere Objekthypothese auf dem Fahrstreifen für das Linksabbiegen, dadurch ist ein Übergang in das Modell für das Linksabbiegen wahrscheinlich. Die Angabe einer einzelnen Übergangsmatrix, die beiden Situationen gerecht wird, ist nicht möglich. Daher wird eine individuelle Situations- und Ortsadaption der Übergangsmatrix für jede Objekthypothese notwendig. Da es keiner der bisher bekannten Ansätze schafft, die Orts- und Situationsabhängigkeit der Übergangswahrscheinlichkeiten allgemeingültig zu lösen, besteht zu diesem Punkt ein Forschungsbedarf.

2.3.2 Hybride Umfeldmodelle: Fusion von objekt- und gitterbasierter Darstellung

Im Fokus zahlreicher Aktivitäten stehen Ansätze zur getrennten Darstellung von beweglichen Objekthypothesen (objektbasierte Darstellung), Daten aus Navigationskarten (graphenbasierte Darstellung) und stationärer Randbebauung (gitterbasierte Darstellung). Das aus der Kombination dieser unterschiedlichen Darstellungen resultierende Umfeldmodell wird als hybrides Umfeldmodell bezeichnet.

Burlet u. a. (2008) und Baig u. a. (2009) zeigt ein Verfahren, das eine flächige Darstellung der Umgebung (lokale Karte) erstellt und eine Positionierung auf dieser ermöglicht. Diese Karte wird genutzt, um bewegliche Objekthypothesen zu erkennen und zu verfolgen. Für das Objekttracking wird ein IMM-Filter um eine Multi-Hypothesen-Assoziation erweitert. Hierbei werden bei der Assoziation von Messungen und vorherigen Zuständen mehrere Zuordnungs-Hypothesen betrachtet. Im IMM-Filter werden 16 Kalman-Filter parallel betrachtet. Die Bewegungsmodelle sind hierbei sternförmig angeordnet und repräsentieren je eine konstante Bewegung in einer Richtung. Die Übergangsmatrix wird hierbei online angepasst. Hierfür werden die Modelle, die sich nahe an der bisher beobachteten Trajektorie befinden, höher gewichtet als die weit davon entfernten Modelle. Zur Erkennung der beweglichen Objekthypothesen wird eine Kombination aus einem widerspruchsbasierten und einem sogenannten Track-Before-Detect Ansatz verfolgt. Hierfür werden in einer Belegkarte die Ergebnisse alle bisher detektierten mit den aktuellen Sensordaten verglichen und nach Widersprüchen gesucht. In einer Dynamikkarte werden Informationen über früher verfolgte bewegliche Objekthypothesen gespeichert. Relevant für diese Arbeit ist die vorgestellte Trennung von beweglichen Objekthypothesen und stationärer Randbebauung mittels einer Kombination aus einem Track-Before-Detect- und einem widerspruchsbasiertem Verfahren.

Rauskolb u. a. (2008), Klose (2008) und Effertz (2009) beschreiben ein hybrides Umfeldmodell für das urbane Umfeld. Es wird ein Verfahren genutzt, das Randbebauung, Straßen und stationäre Hindernisse in sogenannten ortsbasierten Karten beschreibt. Objekthypothesen werden in objektbasierten Karten abgebildet. Effertz (2009) beschreibt die Umsetzung des Objekthypothesentrackings und der ortsbasierten Karte. Um eine gleichzeitige Konturschätzung für Randbebauung und Objekte zu realisieren, werden die Objekthypothesen über Polygonzüge beschrieben. Dies ermöglicht es, eine Vielzahl verschiedener Konturformen zu modellieren. Dieser Ansatz wird in Ohl u. Maurer (2011a) und Ohl u. Maurer (2011b) weiterverfolgt und optimiert. Es werden zwei unterschiedliche Bewegungsmodelle genutzt: konstante Kurvenfahrt und ein Modell für einen stationären Zustand. Um die Objekthypothesen zu plausibilisieren, wird eine Höhen- bzw. Befahrbarkeitskarte eingesetzt. Diese ermöglicht es, Objekthypothesen, die z. B. von Bodenechos verursacht worden sind, von solchen zu unterscheiden, die von realen beweglichen Objekten stammen. Relevant für diese Arbeit ist die Verwaltung von stationärer Randbebauung in ortsbasierten- und die Verwaltung von beweglichen Objekthypothesen in objektbasierten-Karten.

Darms (2008) beschreibt ein hybrides Umfeldmodell für das urbane Umfeld. Hierbei werden stationäre Objekthypothesen und bewegliche Objekthypothesen getrennt. Stationäre Objekthypothesen werden in einer gitterbasierten Darstellung abgelegt, bewegliche Objekt-

hypothesen werden in Objektlisten verwaltet. Die Trennung erfolgt über einen Abgleich von Navigationskartendaten und der gitterbasierten Darstellung. Objekthypothesen, die sich in einem ansonsten befahrbaren Raum befinden, werden als beweglich klassifiziert. Relevant für diese Arbeit ist die Trennung von beweglichen Objekthypothesen und stationärer Randbebauung anhand von Navigationskartendaten.

Leonard u. a. (2008) nutzen ein hybrides Umfeldmodell für die Modellierung des urbanen Umfelds. Es wird eine gitterbasierte Darstellung für langsame Objekte und stationäre Hindernisse aufgebaut. Hierfür werden verschiedene Laserscanner genutzt. Schnell bewegte Objekte werden in Objektlisten verwaltet und mittels eines IMM-Filters verfolgt. Für die Detektion der schnell bewegten Objekthypothesen werden Radar-Sensoren eingesetzt. Eine Fusion aus Radar- und Lasersensoren findet nicht statt, daher werden langsame Objekthypothesen bei diesem Ansatz nicht von stationären unterschieden. Relevant für diese Arbeit ist die Trennung von beweglichen Objekthypothesen und stationärer Randbebauung anhand verschiedener Sensoren. Laserscanner füllen eine gitterbasierte Darstellung, Radarsensoren füllen eine objektbasierte Darstellung für schnell bewegte Objekthypothesen.

Petrovskaya u. Thrun (2008) stellen ein hybrides Umfeldmodell für die urbane Umfeldwahrnehmung vor. Für das Objekttracking werden bewegliche Objekthypothesen mit einem rechteckigen Konturmodell approximiert. Bei Änderungen der Kontur durch Perspektivwechsel wird ein Positionsoffset des Referenzpunktes geschätzt. Für die Zustandshypothesenschätzung wird eine Kombination aus Partikel- und Extended-Kalman-Filter, das Rao-Blackwellized-Partikel-Filter (RBPF), genutzt. Die Idee besteht darin, die mit der Dimensionalität des Zustandsvektor exponentiell ansteigende Anzahl Partikel N_S zu begrenzen, indem der Zustandsvektor geteilt wird. Position und Geschwindigkeit werden mittels eines Partikelfilters geschätzt. Konturinformationen und der Positionsoffset des Referenzpunktes bei Perspektivwechseln werden mit Hilfe eines Extended-Kalman-Filters geschätzt. Stationäre Randbebauung wird in einer gitterbasierten Darstellung abgelegt. Relevant für diese Arbeit ist der Einsatz eines aufwändigen Objekttracking-Verfahrens in urbaner Umgebung. Dies ist durch die Verringerung der Anzahl der Objekthypothesen in der objektbasierten Darstellung möglich. Realisiert wird dies durch eine Trennung von beweglichen Objekthypothesen und stationärer Randbebauung.

Wang u. Thorpe (2002) und Wang (2004) beschreiben einen Ansatz zur Erkennung und Verfolgung beweglicher Objekthypothesen (Detection and Tracking of Moving Objects (DAT-MO)). Für die Erkennung der beweglichen Objekte wird folgender Ansatz vorgestellt: Alle Daten werden in einer flächigen Darstellung gespeichert und jeder neue Scan wird anschlie-

ßend mit der Historie verglichen. Treten Widersprüche auf, so ist dies ein Hinweis auf Bewegung in der betrachteten Szenerie. Zusätzlich werden Informationen über bisher gesehene Objekthypothesen in einer weiteren Gitterstruktur gespeichert. Die Annahme ist hierbei, dass an Stellen, an denen zuvor bewegte Objekthypothesen detektiert wurden, die Wahrscheinlichkeit weiterer beweglicher Objekthypothesen erhöht ist. Relevant für diese Arbeit ist die Trennung von beweglichen Objekthypothesen und stationärer Randbebauung anhand einer Kombination aus einem widerspruchsbasierten Ansatz und einer gitterbasierten Bewegungs-Historie.

Wille u. a. (2010) stellen das im Rahmen des Projekts Stadtpilot eingesetzte Umfeldmodell vor. Für die Erkennung von stationären Frei- und Belegtbereichen wird eine gitterbasierte Darstellungsform verwendet. Für bewegliche Objekte wird eine objektbasierte Darstellungsform gewählt. Des Weiteren wird ein graphenbasiertes Umfeldmodell zur Bahnplanung und zur Verbesserung des Szenenverständnisses eingesetzt. Die für das graphenbasierte Umfeldmodell benötigte genaue Ortung wird über ein satellitengestütztes Koppelnavigationssystem realisiert. Relevant für diese Arbeit ist die Verwendung eines graphenbasierten Umfeldmodells für die Verbesserung des Szenenverständnisses.

Bouzouraa u. Hofmann (2010) und Bouzouraa u. Hofmann (2011) stellen ein Verfahren zur Fusion von Objekttracking und einer widerspruchsbasierten Gitterstruktur dar. Die Objekthypothesen werden aus dem Tracking mit den in den Zellen gespeicherten Dynamikinformationen assoziiert und gegenseitig korrigiert. Hierfür werden die Gitterzellen anhand eines Geschwindigkeitsvektors in jedem Schritt prädiert. Insgesamt entsteht so eine objektbasierte Darstellung der beweglichen Verkehrsteilnehmer und eine gitterbasierte Darstellung der belegten und freien Bereiche. Für das Objekttracking wird eine Global-Nearest-Neighbour-Assoziation (GNN) mit einem Multi-Hypothesen-Tracking (MHT) verwendet. Relevant für diese Arbeit ist die Multiobjektverfolgung von beweglichen Objekthypothesen in einer gitterbasierten Struktur. Realisiert wird dies durch das Verschieben der einer Objekthypothese zugeordneten Gitterzellen.

Fazit: Objektmodelle unter der Berücksichtigung hybrider Umfeldmodelle

Hybride Umfeldmodelle stehen seit der Urban Challenge im Jahre 2007 im Fokus zahlreicher Forschungsaktivitäten im Bereich der automobilen, maschinellen Umfeldmodellierung. Die in Effertz (2008), Rauskolb u. a. (2008) und Ohl u. Maurer (2011b) beschriebenen Ansätze benötigen Objekt- und Dynamikmodelle, die sowohl ausgedehnte und stationäre Strukturen (Randbebauung) als auch bewegliche Fahrzeuge beherrschen. Die Weiterentwicklung der

z. B. in Burlet u. a. (2008), Darms (2008), Leonard u. a. (2008), Klose (2008), Petrovskaya u. Thrun (2008) und Baig u. a. (2009) beschriebenen Algorithmen bietet die weitergehende Möglichkeit *der konsequenten Trennung von beweglichen Objekthypothesen und stationärer Randbebauung*: Stationäre Randbebauung wird bei diesen Ansätzen in einer gitterbasierten Darstellung abgebildet, bewegliche Objekthypothesen werden in einer objektbasierten Darstellung abgelegt. Dies verringert die Anzahl der Objekthypothesen in der objektbasierten Darstellung und schafft so die Möglichkeit, im urbanen Umfeld aufwändigere Multi-Hypothesen-Verfahren in Echtzeit anzuwenden. Darüber hinaus wird es möglich, Modelle gezielt für bewegliche Objekte zu entwickeln. Bisher werden hierfür vor allem rechteckige Boxen als Approximation genutzt (vgl. Petrovskaya u. Thrun 2008). Abbildungen 2.11 und 2.12 zeigen, dass das häufig verwendete rechteckige *Objektmodell* selbst für die Gattung der PKW keine allgemeingültige Approximation darstellt. Wird zusätzlich die Vielzahl anderer in Kreuzungsbereichen auftretender Verkehrsteilnehmer bedacht (LKW, Busse, Radfahrer, Fußgänger), so zeigt dies weitere Grenzen bei der Allgemeingültigkeit dieser Approximation auf.

Hybride Umfeldmodelle werden im Allgemeinen in einer High-Level-Fusion zu einem konsistenten Umfeldmodell fusioniert. Dies führt zu einem Umfeldmodell, das hohen Anforderungen, wie z. B. beim automatischen Fahren, genügt. Beispielhaft ist eine solche High-Level-Fusion in Abbildung 2.13 (blaue Pfeile) schematisch dargestellt. Die in Abbildung 2.13 (rote Pfeile) gezeigte *Möglichkeit einer Low-Level-Fusion* der verschiedenen Darstellungsformen ist bisher nicht ausführlich thematisiert worden. Entsprechend besteht ein Forschungsbedarf.



Bild 2.11: Abbildung eines VW Golfs aus der Vogelperspektive im Vergleich zu einer rechteckigen Konturapproximation.



Bild 2.12: Abbildung eines VW Passats aus der Vogelperspektive im Vergleich zu einer rechteckigen Konturapproximation.

Damit ergibt sich für, im Kontext hybrider Umfeldmodelle, eingesetzte Objektmodelle

folgender Forschungsbedarf: Objektmodelle müssen im Kontext des verwendeten hybriden Umfeldmodells nicht mehr in der Lage sein, unstrukturierte Randbebauung zu modellieren und werden daher für typische bewegliche Objekthypothesen optimiert. Die Trennung von beweglichen Objekthypothesen und stationärer Randbebauung verringert die Anzahl der Objekthypothesen im objektbasierten Umfeldmodell. Dies ermöglicht den Einsatz aufwändigerer Multi-Modell-Verfahren.

Fazit: Sensorsetup

Aktuell gibt es im Serieneinsatz kein maschinelles Wahrnehmungssystem, das geeignet ist *in Kreuzungsbereichen Längs- und Querverkehr zu verfolgen*. Im Serieneinsatz befindliche Sensorik ist bezüglich Öffnungswinkel und Einbauposition auf Längsverkehr optimiert und somit nur sehr eingeschränkt in der Lage, Querverkehr zu verfolgen (siehe Abschnitt 2.2.1). Bisherige Forschungsbeiträge (vgl. Klose 2008, Rauskolb u. a. 2008, Darms 2008, Leonard u. a. 2008, Petrovskaya u. Thrun 2008, Effertz 2009 und Wille u. a. 2010) zum Multiobjekttracking im urbanen Umfeld verwenden aufwändige Fusionen aus zahlreichen Sensoren (verwendet werden hierbei unterschiedlichste Kombinationen aus Laser-, Kamera- und Radarsensoren) zur Lösung der Problemstellung. Roessler (2010) verwendet eine Fusion aus zwei Laserscannern und einer Kamera zur Realisierung eines Kreuzungsassistenten. Durch die Vielzahl der Sensoren sind diese vorgestellten Ansätze wirtschaftlich für eine Entwicklung der Systeme in Richtung Serieneinsatz nur schwer realisierbar. Ferner benötigen die bisher eingesetzten Laserscanner, die über bis zu 64 Ebenen verfügen, unter anderem Bauraum auf dem Fahrzeugdach und sind daher auch aus Designgründen nicht für einen Serieneinsatz im automobilen Umfeld geeignet. Bisher in der Forschung eingesetzte Sensorsetups, zur maschinellen Umfeldwahrnehmung im urbanen Umfeld, bestehen aus einer Vielzahl aufwändiger und visuell nicht serientauglicher Sensoren. Am Markt verfügbare Seriensenorik ist nach aktuellem Stand der Technik für Längsverkehr optimiert. Daher besteht ein Forschungsbedarf bezüglich der urbanen Multiobjektverfolgung von Längs- und Querverkehr mittels eines seriennahen, in das Fahrzeug-Design integrierbaren Sensors.

2.3.3 Verwendung von digitalem Kartenmaterial zur Verbesserung des Szenenverständnisses

Kapitel 2.1 hat ausgewählte Forschungsprojekte vorgestellt, welche Navigationskartendaten zu einer Verbesserung des Szenarienverständnisses nutzen. Einige Ansätze werden im Folgenden diskutiert:

Knaup u. Homeier (2010) beschreibt ein graphenbasiertes Umfeldmodell zur verbesserten Szeneninterpretation (als Roadgraph bezeichnet). Es fusioniert verschiedene Quellen wie Navigationsdaten, Sensordaten und Daten aus C2X-Kommunikation in einem Modell. Dieses besteht aus Kanten und Knoten. Kanten repräsentieren Fahrstreifen, Knoten repräsentieren Kreuzungspunkte. Die Objekte der verschiedenen Quellen werden diesen Kanten zugeordnet (Map-Matching). Die Kanten enthalten dabei detaillierte Informationen wie z. B. Informationen über Verkehrsschilder, Tempolimits, Straßennamen, Lichtsignalanlagen, Abbiegemöglichkeiten und erwartete Geschwindigkeiten. Homeier u. Wolf (2011) beschreibt einen Ansatz zur High-Level-Fusion von Objekten aus verschiedenen Quellen (in das Fahrzeug integrierte Sensorik und Infrastruktur-Sensorik) in einem graphenbasierten Umfeldmodell. Durch die Zuordnung der Objekte zu den Kanten des graphenbasierten Umfeldmodells entsteht die Möglichkeit, Objekthypothesen mit a-priori Informationen aus Navigationskartendaten zu kombinieren und so z. B. die Prädiktion vor der Assoziation zu beeinflussen. Relevant im Kontext dieser Arbeit ist der Ansatz, graphenbasierte Umfeldmodelle um dynamische Informationen wie z. B. bewegliche Objekthypothesen anzureichern und das gewonnene Szenenverständnis für eine High-Level-Fusion der Daten zu nutzen.

Roessler (2010) beschreibt ein Assistenzsystem für Kreuzungen. Der Schwerpunkt dieses Systems liegt hierbei hauptsächlich auf der Generierung eines Szenarienvverständnisses und der darauf basierenden Bewertung des Risikos der jeweiligen Situation. Für das Objekttracking wird ein IMM-Filter mit drei Dynamikmodellen verwendet: Stillstand, Bewegung mit konstanter Geschwindigkeit und Bewegung mit konstanter Beschleunigung. Für den Aufbau eines Szenarienvverständnisses wird ein graphenbasiertes Umfeldmodell, bestehend aus Kanten und Knoten, genutzt. Dieses wird zur Bewertung von Fahrer- und Objektintention und damit zur Bewertung des Risikopotenzials der Situation genutzt. Hierfür werden Objekthypothesen den Kanten zugeordnet und ein Konfliktgraph mit möglichen Kollisionspunkten ermittelt. Relevant im Kontext dieser Arbeit ist der Ansatz, graphenbasierte Umfeldmodelle zur Verbesserung der Situationsinterpretation einzusetzen.

Ke u. a. (2000) leisten in einer Simulation einen Beitrag zur Betrachtung alternativer Objekttracking-Methoden. Betrachtet wird das Objekthypothesen-Tracking unter der Einbeziehung zusätzlicher Informationen über den Straßenverlauf. Verglichen wird ein IMM-Filter mit einem Kalman-Filter, dessen Prozessrauschen an den Straßenverlauf angepasst wird. Überdies wird ein Kalman-Filter vorgestellt und in den Vergleich einbezogen, indem die Ausrichtung der Objekthypothese entlang der Fahrbahn korrigiert wird. Außerdem wird ein Hidden-Markov-Modell (HMM) unter der Einbeziehung zusätzlicher Informationen vorgestellt. Es wird gezeigt, dass zusätzliche Informationen die Ergebnisse des Trackings, gemessen

sen an der Wurzel des quadratischen Fehlers, verbessern. Relevant im Kontext dieser Arbeit ist der Ansatz, Informationen aus graphenbasierten Umfeldmodellen in der Multiobjektverfolgung zu nutzen.

Fazit: Berücksichtigung von Navigationskartendaten zur Minimierung der Zustandsunsicherheit in der Multiobjektverfolgung

Die in Abschnitt 2.1 beschriebenen und in Abschnitt 2.1.4 rekapitulierten Forschungsprojekte zeigen einen Trend zur High-Level-Fusion von Daten aus der Sensorik, den Navigationskarten und den Daten aus C2X-Kommunikation auf. Begünstigt wird dieser Trend durch immer genauere Navigationskarten und verbesserte Möglichkeiten zur Positionsbestimmung im urbanen Umfeld. Die durch eine *Positionierung auf den Navigationskarten* entstehende zusätzliche Informationsbasis schafft neue Möglichkeiten und wird bei den beschriebenen Ansätzen (vgl. Knaup u. Homeier 2010, Roessler 2010 und Homeier u. Wolf 2011) mittels eines graphenbasierten Umfeldmodells ausdrücklich zur Verbesserung des Szenarienvverständnisses eingesetzt. Nur wenige Beiträge (z. B. Ke u. a. 2000) widmen sich einer Low-Level-Fusion von Navigationskartendaten und Objekttracking-Algorithmen. Bezüglich der Low-Level-Fusion von graphenbasierten Umfeldmodellen und den Objekttracking-Algorithmen zur Minimierung der Zustandsunsicherheit der Objekthypothesen (vgl. Bild 2.13) besteht ein Forschungsbedarf.

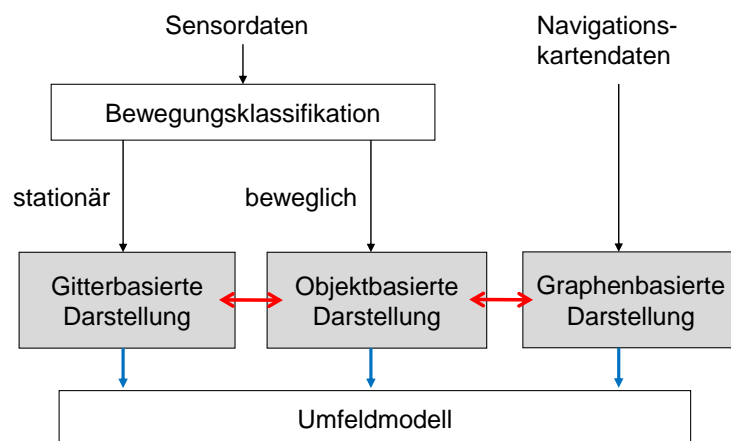


Bild 2.13: Beispielhafte schematische Darstellung eines hybriden Umfeldmodells. Die blauen Pfeile beschreiben die Möglichkeit einer High-Level-Fusion, die roten Pfeile die Möglichkeit einer Low-Level-Fusion.

2.3.4 Güte- und Konsistenzkriterien zur Bewertung des Objekttrackings

Zur Bewertung von Objekttracking-Algorithmen sind objektive Güte- und Konsistenzkriterien notwendig. Grundsätzlich wird zwischen Kriterien, die eine Referenz benötigen und Kriterien, die ohne eine solche auskommen, unterschieden. Bei den Kriterien, die eine Referenz benötigen, liegt die Herausforderung in der Entwicklung von Referenzierungskonzepten für komplexe, urbane Kreuzungsszenarien. Im Folgenden wird ein Überblick über bei der Bewertung von Multiobjektverfolgungs-Algorithmen anerkannte Güte- und Konsistenzkriterien gegeben. Folgende Kriterien benötigen hierfür Referenzdaten:

- **Normalisiertes Fehlerquadrat (NEES):** Test, der Daten einer Referenz benötigt (vgl. Bar-Shalom u. a. 2001, S. 489, dort als Normalized Estimation Error Squared bezeichnet).

$$NEES = \hat{\mathbf{x}}^T \mathbf{P}_{k|k}^{-1} \hat{\mathbf{x}} \quad (2.42)$$

$$= (\mathbf{x}_k^{REF} - \hat{\mathbf{x}}_{k|k})^T \mathbf{P}_{k|k}^{-1} (\mathbf{x}_k^{REF} - \hat{\mathbf{x}}_{k|k}) \quad (2.43)$$

- **Zeitliche Abdeckung (ZA):** Beschreibt nach Lindl (2008) den Prozentsatz der Zeit, in der das Objekt λ verfolgt werden konnte. t_λ sei hierbei die Zeit, in der die Objekthypothese verfolgt wurde und l_λ seine Lebensdauer.

$$ZA = \frac{\sum_\lambda t_\lambda}{\sum_\lambda l_\lambda} \quad (2.44)$$

- **Mittelwert der Wurzel des quadratischen Fehlers (RMSE):** Beschreibt die Wurzel aus der mittleren quadratischen Abweichung der Schätzung der Ortskoordinaten von einer Referenz (vgl. Bar-Shalom u. a. 2011, S. 1010, dort als Root Mean Square Error bezeichnet).

$$RMSE = \frac{1}{N} \sum_{i=1}^N \sqrt{\frac{(x_i - x_i^{REF})^2 + (y_i - y_i^{REF})^2}{2}} \quad (2.45)$$

Auf Grund der nicht immer verfügbaren Referenz (der Begriff der Referenz in diesem Zusammenhang wird in Abschnitt 3.1 erläutert) haben sich auch Gütekriterien etabliert, die ohne eine Referenz auskommen. Da diese Verfahren keine Referenz benötigen, besteht außerdem die Möglichkeit, diese Kriterien online zu berechnen und zu überwachen:

- **Normalisiertes Quadrat der Innovation (NIS):** Test, der ohne die Daten einer

Referenz auskommt (vgl. Bar-Shalom u. a. 2001, S. 236, dort als Normalized Innovation Squared bezeichnet):

$$NIS = \nu \mathbf{S}^{-1} \nu \quad (2.46)$$

$$= (\mathbf{z} - \mathbf{H}\hat{\mathbf{x}}_{k|k-1})^T (\mathbf{H}\mathbf{P}_{k|k-1}\mathbf{H}^T + \mathbf{R})^{-1} (\mathbf{z} - \mathbf{H}\hat{\mathbf{x}}_{k|k-1}) \quad (2.47)$$

Dieser Test ist für Filter mit gemischter Verteilung nicht anwendbar (z. B. IMM-Filter), da hier multiple Innovationsvektoren (ν^j) verwendet werden. Alternativ wird hier z. B. das normalisierte Fehlerquadrat (NEES) verwendet. Dieser Konsistenztest benötigt dann allerdings eine Referenz und ist nicht mehr online-fähig.

Fazit: Bewertung von Objekttracking Ansätzen

Die objektive Bewertung gewinnt, unter der Berücksichtigung der Entwicklung der Assistenzsysteme von den Komfort- zu den Sicherheitssystemen, zunehmend an Bedeutung. Je sicherheitskritischer die Eingriffe der Systeme in die Fahrzeugaktuatorik werden, desto mehr rückt in den Vordergrund, zu bewerten, wie gut die Systeme ihren Anforderungen gerecht werden. Erst der konsequente Vergleich der Algorithmen mit einer Referenz ermöglicht es, Gütekriterien zu definieren und verschiedene Algorithmen miteinander zu vergleichen. Dies macht es möglich, den subjektiven Expertenblick durch objektiv bewertbare und reproduzierbare Kriterien zu ersetzen. Die mit den aus der Literatur bekannten Konsistenztests (vgl. Bar-Shalom u. a. 2001, S. 236, Stüker 2004, Lindl 2008 und Mählich 2009) bewertbare Konsistenz der Algorithmen ist infolge notwendig, aber nicht hinreichend. Neben den verschiedenen Formen der Gütemaße für quadratische Abweichungen zwischen Schätzung und Referenz sind weiterhin Gütekriterien zur Bewertung von dynamischen Vorgängen notwendig. Allgemein anerkannte Gütekriterien zur Bewertung solcher Vorgänge haben sich bisher nicht etabliert, daher besteht ein Forschungsbedarf.

2.3.5 Grenzen des Stands der Technik und der abgeleitete Forschungsbedarf

Wird der in Abschnitt 2.3 vorgestellte Stand der Technik zum Objekttracking im urbanen Umfeld betrachtet, so lässt sich daraus zusammenfassend folgender Forschungsbedarf identifizieren:

- Bisherige in der Forschung verwendete Sensorsetups zur maschinellen Umfeldwahrnehmung im urbanen Kontext bestehen aus einer Vielzahl aufwändiger und visuell nicht serientauglicher Sensoren. Am Markt verfügbare Seriensensorik ist nach aktuellem Stand

der Technik nicht in der Lage, Querverkehr zu detektieren. Bei der Realisierung einer maschinellen Umfeldwahrnehmung im urbanen Umfeld mittels eines Sensors, der bezüglich Eigenschaften und Kostenstruktur seriennah ist, besteht Forschungsbedarf.

- Hybride Umfeldmodelle schaffen die Möglichkeit, Algorithmen zur Low-Level- und zur High-Level-Fusion von objekt- mit gitter- und graphenbasierten Darstellungsformen zu entwickeln. Bezüglich der Low-Level-Fusion besteht Forschungsbedarf.
- Keine der bisher bekannten Lösungen schafft es, die Orts- und Situationsabhängigkeit der Übergangswahrscheinlichkeiten des IMM-Filters allgemeingültig zu lösen. Bezüglich der Adaption der Übergangsmatrix zur Laufzeit besteht Forschungsbedarf. Zudem besteht bezüglich der Berücksichtigung wechselnder querdynamischer Manöver in Kreuzungsbereichen Forschungsbedarf.

2.4 Technische Zielsetzung und Randbedingungen dieser Arbeit

Primäre Zielsetzung dieser Arbeit ist es, *mit einem festverbauten Laserscanner*, der bezüglich seiner Bauform, der Fahrzeugintegration und der Hardware-Kosten das konzeptionelle Potenzial hat, mittelfristig serientauglich zu werden, eine maschinelle Multiobjektverfolgung für das urbane Umfeld zu realisieren. Hierfür werden die im Kontext hybrider Umfeldmodelle existierenden graphen- und gitterbasierten Darstellungsformen als zusätzliche Informationen zur Minimierung der Zustandsunsicherheit in der objektbasierten Umfeldmodellierung genutzt. Vor allem die Berücksichtigung von Querdynamik ist in bisherigen Ansätzen nur unzureichend adressiert worden. Da diese in *Kreuzungsbereichen* mit einer erhöhten Wahrscheinlichkeit auftritt, steht insbesondere die Minimierung der Zustandsunsicherheit bei querdynamischen Vorgängen im Kreuzungsbereich im Fokus dieser Arbeit. Die Ziele dieser Arbeit werden in Tabelle 2.2 dargestellt.

Abs.	Gegenstand	Grenzen des Stands der Technik	Ziel dieser Arbeit
2.3.1	querdynamische Vorgänge in Kreuzungsbereichen	a-priori notwendig: Stochastische Bestimmung der Übergangsmatrizen	situationsabhängige Anpassung zur Laufzeit
2.3.2	Fusion objekt- und gitterbasierter Darstellungen	Beschränkung auf High-Level-Fusion zur Verbesserung des Szenenverständnisses	Low-Level-Fusion
2.3.2	Sensorsetup	Realisierung bisher mit aufwändigen und serienuntauglichen Sensorsetups	Verwendung eines einzelnen seriennahen Laserscanners
2.3.3	Fusion objekt- und graphenbasierter Darstellungen	Beschränkung auf High-Level-Fusion zur Verbesserung des Szenenverständnisses	Low-Level-Fusion
2.3.4	Gütekriterien	Beschränkung auf Bewertung von Abweichungen und Konsistenztests	Bewertung dynamischer Vorgänge

Tabelle 2.2: Tabellarische Übersicht des Standes der Technik und der abgeleiteten Ziele dieser Arbeit.

3 Entwicklungsmethodik und Gütekriterien

Sowohl Objekttracking-Algorithmen als auch Sensoren befinden sich zum Teil seit mehreren Produktgenerationen im Serieneinsatz. Neben der Erschließung neuer Einsatzgebiete, wie z. B. des urbanen Umfeldes, gewinnt zunehmend der Aspekt der Leistungssteigerung bzw. Verbesserung von Sensoren und Algorithmen an Bedeutung. Eine Leistungssteigerung ist jedoch nur nachweisbar, wenn zuvor, anhand anerkannter *Gütekriterien*, eine Verbesserung aufgezeigt wird. In Abschnitt 3.1 wird ein Überblick über die Anforderungen und Begrifflichkeiten zur Messdatenerhebung gegeben. Anschließend werden zunächst Anforderungen an ein Entwicklungskonzept gestellt (Abschnitt 3.2). Daraufhin wird ein Konzept vorgestellt, das eine Bewertung der Algorithmen anhand der zuvor definierten Kriterien von der modellbasierten Entwicklung bis zur Implementierung auf der Zielumgebung unterstützt. Abschnitt 3.3 stellt verschiedene Gütekriterien vor und wählt einen Satz aussagekräftiger Kriterien aus, die im Weiteren die Basis der experimentellen Validierung bilden. In Abschnitt 3.4 werden die Ergebnisse dargestellt und diskutiert (vgl. Bild 3.1).




Bild 3.1: Grafische Darstellung der Gliederung von Kapitel 3

3.1 Begriffsdefinition

Die Anforderungen und Begrifflichkeiten der Datenerhebung in der empirischen Wissenschaft werden im Folgenden erläutert:

Objektivität: Die erhobenen Daten werden weder von der durchführenden Person, noch von der eingesetzten Methodik bzw. Technik inhaltlich verfälscht bzw. manipuliert. Die Datenerhebung ist somit objektiv.

Reliabilität: Findet die Datenerhebung zu einem anderen Zeitpunkt unter gleichen Bedingungen statt, so führt dies zu vergleichbaren Ergebnissen. Die Messungen sind reproduzierbar.

Validität: Die eingesetzte Datenerhebungsmethode ist zur Erhebung der Daten geeignet. Zugleich sind die erhobenen Daten geeignet, um die Arbeitshypothese falsifizieren bzw. validieren zu können. Die erhobenen Daten sind somit belastbar.

Referenz: Bei der Betrachtung der Referenz ist zwischen simulierten und realen Messdaten zu unterscheiden. Für die simulierten Daten liegt mit den wahren Trajektorien der Objekte (Ground-Truth) eine geeignete Referenz vor. Problematischer ist die Referenzierung für reale Messdaten (vgl. z. B. Brahmi 2013): Gerade für komplexe Szenarien ist die vollständige Referenzierung der Umgebung aufwändig und nach aktuellem Stand der Technik nicht realisierbar. Die Entwicklung von *Referenzsensorik* für urbane Szenarien bleibt Gegenstand weiterer Forschungsaktivitäten. Im Rahmen dieser Arbeit wird daher auf eine vollständige Referenzierung der Szenerie verzichtet. Im Rahmen der technischen Möglichkeiten werden nur das Ego-Fahrzeug und ein Objekt referenziert. Für die Generierung der Referenzdaten benötigen das Objekt und ebenso das Ego-Fahrzeug ein System zur Bestimmung von Position, Geschwindigkeit und Ausrichtung. Zur Referenzierung der bewegten Fahrzeuge wird ein satellitengestütztes Koppelnavigationssystem der Firma Oxford Technical Solutions Limited (oxts) genutzt. Es handelt sich um das System mit der Bezeichnung RT3002 mit den in Tabelle 3.1 beschriebenen technischen Daten. Die Ausgaben dieses Sensors sind mit Hilfe eines Kalman-Filters (Eingangsgrößen: Satellitendaten, Inertialkreisler, Odometer) geschätzt. Problematisch sind hierbei zwei Aspekte: Das eingesetzte System und ähnliche Produkte basieren auf dem Global Positioning System (GPS). Gerade innerorts gibt es häufig nur eine eingeschränkte oder gar keine Verfügbarkeit. Zusätzlich sind GPS-Fehler in der Regel nicht normalverteilt, die Angabe einer Präzision in einer σ -Region ist daher häufig falsch und somit kritisch zu hinterfragen. Ist kein GPS-Empfang vorhanden, so werden die Ausgaben nur noch durch die Inertialkreisler und das Odometer gestützt. Hierbei ist anzumerken, dass die im eingesetzten System verwendeten Komponenten nur als durchschnittlich anzusehen sind. Ein Einsatz in Regionen mit GPS-Unterbrechung ist daher besonders kritisch zu betrachten. Daher wird das Referenzsystem im Kontext dieser Arbeit nur unter freiem Himmel eingesetzt; auf einen Einsatz in Gebieten mit GPS-Abschattung wird verzichtet. Unter freiem Himmel liefert das System eine Richtigkeit, die laut Datenblatt um den Faktor 10-25 höher liegt als die Richtigkeit der verwendeten und zu bewertenden Lasersensorik samt nachgelagerter Algorithmen. Das System bildet damit eine geeignete Referenz, liefert allerdings auf

Grund von Unsicherheiten nicht die wahre Trajektorie der Objekte (Ground-Truth).

Richtigkeit	oxts RT3002
· der Position	bis zu 2cm (1σ)
· der Geschwindigkeit	$0,05 \frac{km}{h}$ (mittlerer quadratischer Fehler)
· der Beschleunigung (Bias)	$10 \frac{mm}{s^2}$ (1σ)
· des Wank- und Nickwinkels	$0,03^\circ$ (1σ)
· des Gierwinkels	$0,1^\circ$ (1σ)
· des Schwimmwinkels	$0,15^\circ$ (1σ)

Tabelle 3.1: Technische Daten des satellitengestützten Koppelnavigationssystems RT3002 der Firma Oxford Technical Solutions Limited (oxts).

3.2 Entwicklungsmethodik

Der Entwicklungsprozess von Fahrerassistenzsystemen beginnt bei Automobilherstellern üblicherweise mit der Identifikation der relevanten Szenarien durch die Analyse von Unfalldatenbanken. Diese Szenarien werden genutzt, um Anforderungen an das System zu definieren. Um den Entwicklungsprozess von der Unfallforschung in das Zielsystem Fahrzeug begleiten zu können, werden folgende Anforderungen an ein Konzept gestellt: Es wird verlangt, aus Unfallanalysen abgeleitete Szenarien mit einer hohen Reliabilität zu simulieren. Dies ermöglicht eine gezielte Darstellung der für die Algorithmen-Entwicklung notwendigen Szenarien. Des Weiteren besteht der Anspruch, die simulierten Messdaten durch die mit dem Versuchsträger aufgezeichneten Messdaten zu ersetzen. Hierfür werden reale Sensormessdaten erhoben. Um die Algorithmen zu vergleichen und zu bewerten, ist eine hohe Validität und Reliabilität der erhobenen Daten notwendig. Hierfür wird gefordert, dass für reale und für simulierte Szenarien eine objektive und belastbare Referenz zur Verfügung steht.

Das Konzept des Lösungsansatzes erlaubt es, simulierte und reale Messdaten mit derselben Auswertalgorithmik zu bewerten. Der Aufbau wird in Bild 3.2 skizziert. Bild 3.2 zeigt drei Möglichkeiten auf, um von der Sensordatenerzeugung zu einer Auswertung gegenüber einer Referenz zu gelangen: Eine modellbasierte Variante und zwei auf realen Messdaten basierenden Varianten (Online- und Offline-Betrieb der Algorithmen). Basierend auf den generierten Sensordaten werden die Tracking-Algorithmen modellbasiert entwickelt und validiert. Die Auswertelogik vergleicht die durch die Algorithmen generierten Größen mit der Referenz. Darüber hinaus werden die Algorithmen mit realen Messdaten validiert und weiterentwickelt. Dies hat den Vorteil, dass die Datengrundlage nun nicht mehr auf vereinfachten Modellan-

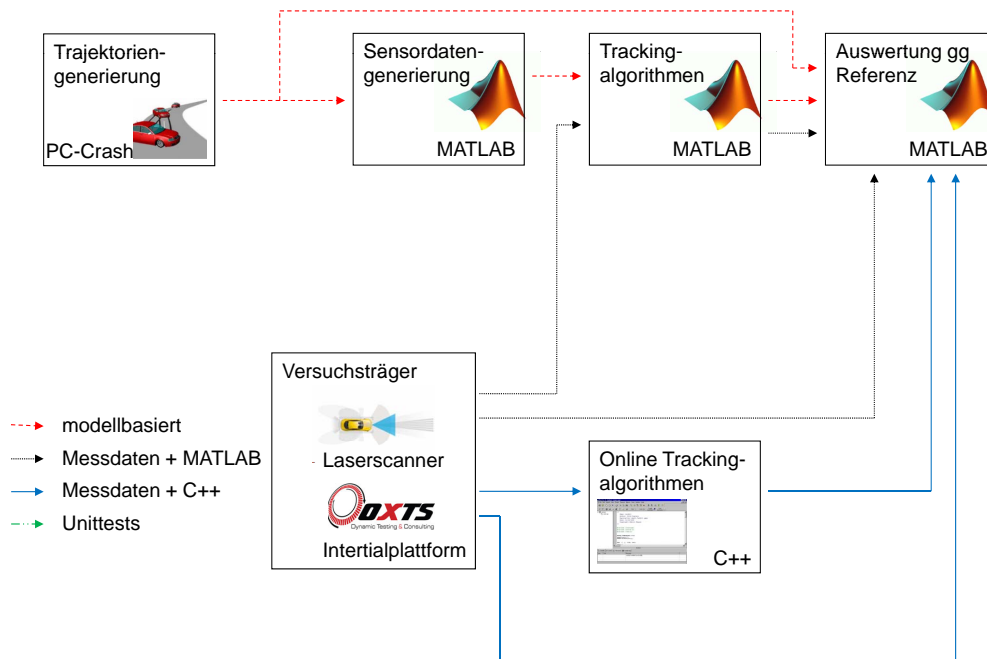


Bild 3.2: Eingesetzte Entwicklungstoolkette

nahmen basiert. Der Nachteil liegt allerdings in der nur noch eingeschränkten Möglichkeit, Manöver exakt zu planen und zu reproduzieren. Ferner ist die Erzeugung exakter Referenzdaten im urbanen Umfeld nach aktuellem Stand der Technik nur eingeschränkt darstellbar (vgl. Abschnitt 3.1).

3.3 Gütekriterien zur Bewertung von Algorithmen zur Objektverfolgung

Die Bewertung von Algorithmen anhand objektiver und reproduzierbarer Gütekriterien ist ein wichtiger Bestandteil der Entwicklungs- und Weiterentwicklungsprozesse.

3.3.1 Abgeleitete Anforderungen an die Bewertung

Die Wahl der Gütekriterien ist eine Herausforderung bei der Bewertung von Tracking-Algorithmen. Im weiteren Verlauf dieser Arbeit stehen die Bewertung und Optimierung von Zustandsunsicherheiten im Fokus. Daher werden Gütekriterien, die eine Bewertung der Zustandsunsicherheit ermöglichen, im Weiteren detaillierter diskutiert. An die Kriterien zur Bewertung der Zustandsschätzung und -unsicherheit von Tracking-Algorithmen bestehen folgende Forderungen:

- **Detektionslatenz:** An die Gütekriterien besteht der Anspruch, eine Bewertung der Detektionslatenz zu ermöglichen. Hierbei sind hauptsächlich die zum Teil konträren Anforderungen an die Dauer und das Überspringen zu berücksichtigen (vgl. Kämpchen 2007). Als Detektionslatenz eines Objektes wird die Zeit von der ersten Messung des realen Objektes bis zur ersten Zustandsschätzung bewertet.
- **Totzeit:** Unter der Totzeit wird die Zeit verstanden, die bei einer bereits verfolgten Objekthypothese vergeht, bis sich eine Änderung beispielsweise der Dynamik des realen Objektes in der Zustandshypothesenschätzung auswirkt.
- **Richtigkeit der Zustandsschätzung:** Von den Gütekriterien wird verlangt, die Richtigkeit der Zustandsschätzung (Abweichung von der Referenz) zu bewerten.
- **Unsicherheiten:** Es wird vorausgesetzt, dass die Präzision, mit der Zustände geschätzt werden, in die Bewertung durch die Gütekriterien einfließen.
- **Gewichtung der Zustände:** Je nach Relevanz besteht der Anspruch, dass die Gütekriterien eine unterschiedliche Gewichtung der verschiedenen Zustände ermöglichen (z. B. Geschwindigkeit und Position oder aber Position in x- und y-Richtung).
- **Echtzeitfähigkeit:** An die Gütekriterien besteht die Forderung, eine Bewertung der Echtzeitfähigkeit der Algorithmen zu ermöglichen. Algorithmen werden in diesem Zusammenhang als echtzeitfähig bezeichnet, wenn sie auf der Zielplattform innerhalb eines Sensorzyklus für alle Objekte zu berechnen sind.

In der Steuerungs- und Regelungstechnik finden sich einige, anerkannte und zum Teil genormte Gütekriterien, die die obigen Anforderungen teilweise erfüllen. Daher werden diese Ansätze im Folgenden erläutert (Abschnitt 3.3.2). In Abschnitt 4.4.2 werden die zuvor vorgestellten Kriterien auf ihre Eignung zur Bewertung der maschinellen Wahrnehmung in urbanen Szenarien mittels Lasersensorik geprüft und Erweiterungen vorgestellt. Ergänzt durch die aus der Literatur bekannten Gütekriterien zur Bewertung maschineller Umfeldwahrnehmung (vorgestellt in Abschnitt 2.3.4), wird ein erweiterter Satz von Gütekriterien zur Bewertung von Zustandsschätzungen vorgeschlagen.

3.3.2 Ansätze aus der Steuerungs- und Regelungstechnik

Das Kalman-Filter kann als optimale Lösung des Beobachter-Entwurf-Problems aufgefasst werden. Es handelt sich um eine Lösung der Riccati-Gleichung (Optimaler Beobachter). Hierbei wird der quadratische Fehler minimiert (verlaufsoptimal und verbrauchsoptimal). Betrachtet man den Vorgang aus stochastischer Sicht, so wird der Einfluss der Rauschterme

minimiert (Messrauschen, Prozessrauschen). Diese Interpretation legt eine Verwendung aus der Regelungstechnik bekannter Gütemaße zur Bewertung von dynamischen Vorgängen wie z. B. Sprungantworten nah. Das Internationale Elektrotechnische Wörterbuch - Teil 351: Leittechnik (IEC 60050-351:2006) definiert hierfür folgende Begrifflichkeiten und allgemein anerkannte Gütemaße zur Bewertung dynamischer Vorgänge (vgl. Abbildung 3.3):

- **Wert im Beharrungszustand:** Zustand bei konstanten Eingangsgrößen (Δx_∞).
- **Sollwert:** Gewünschter Wert der Regelgröße (x_d).
- **Überschwingweite:** Die größte vorübergehende Abweichung der Ausgangsgröße vom Sollwert. Üblicherweise in Prozent ausgedrückt (x_m).
- **Toleranzbereich:** Definierter Toleranzbereich, der die Basis zur Bestimmung von An- und Ausregelzeit bildet ($2 \cdot \Delta x_s$).
- **Anregelzeit:** Zeit, die die Regelgröße nach einer sprungartigen Änderung benötigt, um zum ersten Mal in den Toleranzbereich einzutreten (T_{cr}).
- **Ausregelzeit T_{cs} :** Zeit, die die Regelgröße nach einer sprungartigen Änderung benötigt, um in den Toleranzbereich einzutreten und dort dauerhaft zu verbleiben.
- **Totzeit T_t :** Zeit, die die Regelgröße nach einer sprungartigen Änderung benötigt, um zu antworten.

Weitere anerkannte Gütekriterien der Steuerungs- und Regelungstechnik finden sich in der Fachliteratur wieder, z. B. Lunze (2006, S. 277 ff.) und Lutz u. Wendt (2005, S. 446 ff.):

- **Betragskriterium** bewertet den Betrag der Regelabweichung:

$$J_{abs} = \int_0^\infty |x(t) - x(\infty)| dt \quad (3.1)$$

$$J_{ITAE} = \int_0^\infty |x(t) - x(\infty)| \cdot t \cdot dt \quad (3.2)$$

Dieses Betragskriterium bewertet den Betrag der Regelabweichung gewichtet mit dem zeitlichen Verlauf.

- **Quadratisches Gütekriterium** bewertet die quadratische Differenz zwischen Soll- und Istwert:

$$J = \int_0^\infty (x(t) - x_d)^2 dt \quad (3.3)$$




Bild 3.3: Schematische Darstellung der Begrifflichkeiten einer typischen Sprungantwort nach IEC 60050-351:2006

$$J_{sqr} = \int_0^{\infty} (x(t) - x(\infty))^2 dt \quad (3.4)$$

Das quadratische Gütekriterium bewertet die quadratische Differenz zwischen dem Wert im Beharrungszustand und dem Istwert.

- **Gütekriterium LQ-Regler** bewertet neben dem Einfluss der Regelgröße (verlaufsoptimal) auch den Einfluss der Stellgröße (verbrauchsoptimal). Die Gewichtsverteilung zwischen den beiden Größen wird hierbei durch die Matrizen R und Q bestimmt:

$$J(x_0, u(t)) = \int_0^{\infty} (x^T(t)Qx(t) + u^T(t)Ru(t)) dt \quad (3.5)$$

3.3.3 Erweiterte Gütekriterien zur Bewertung der Zustandsunsicherheit im urbanen Umfeld

Für die experimentelle Validierung der Genauigkeit der Zustandsschätzung im Kontext dieser Arbeit werden folgende Algorithmen verwendet:

- **Normalisiertes Fehlerquadrat (NEES):** Konsistenztest, der Daten einer Referenz

benötigt. Hierbei wird die Unsicherheit der Schätzung in der Bewertung berücksichtigt:

$$NEES = \hat{\mathbf{x}}^T \mathbf{P}_{\mathbf{k}|\mathbf{k}}^{-1} \hat{\mathbf{x}} \quad (3.6)$$

$$= (\mathbf{x}_k^{REF} - \hat{\mathbf{x}}_{k|k})^T \mathbf{P}_{k|k}^{-1} (\mathbf{x}_k^{REF} - \hat{\mathbf{x}}_{k|k}) \quad (3.7)$$

- **Mittelwert der Wurzel des quadratischen Fehlers (RMSE):** Beschreibt die Wurzel aus der mittleren quadratischen Abweichung der Schätzung von einer Referenz (vgl. Bar-Shalom u. a. 2011, S. 1010):

$$RMSE = \frac{1}{N} \sum_{i=1}^N \sqrt{\frac{(x_i - x_i^{REF})^2 + (y_i - y_i^{REF})^2 + (z_i - z_i^{REF})^2}{3}} \quad (3.8)$$

- **Anregelzeit der Detektion T_{cr} , auch als Latenz der Objekthypothese (Latency of the System Track (LT)) oder als Objektdetektionslatenz bezeichnet:** Zeit von der ersten Detektion bis zu dem Zeitpunkt, an dem die Zustandsschätzung der Objekthypothese das erste Mal in den Toleranzbereich eintritt. Hierbei wird der Toleranzbereich $2 \cdot \Delta x_s$ verwendet.
- **Ausregelzeit der Detektion T_{cs} :** Zeit von der ersten Detektion bis zu dem Zeitpunkt, an dem die Zustandsschätzung der Objekthypothese einen Toleranzbereich nicht wieder verlässt. Hierbei wird der Toleranzbereich $2 \cdot \Delta x_s$ verwendet.
- **Totzeit, auch als Latenz der Zustandsschätzung bezeichnet T_t :** Zeit, die die eingeschwungene Zustandsschätzung benötigt, um einer sprunghaften Änderung zu antworten.
- **Echtzeitfähigkeit:** Die Algorithmen werden als echtzeitfähig bezeichnet, wenn sie auf der Zielplattform innerhalb eines Sensorzyklus (in dieser Arbeit: 60 ms) zu berechnen sind.

3.4 Diskussion der Entwicklungsmethodik und Gütekriterien

Die Toolkette unterstützt den schrittweisen Entwicklungsprozess von der Unfallforschung über das Modell bis zur Funktionalität im realen Fahrzeug. Für den Entwicklungsprozess relevante Szenarien werden entweder den Datenbanken und Ergebnissen der Unfallforschung entnommen oder gemäß der Anforderungen selbst erstellt. Dies ermöglicht es, das subjektive Expertenwissen eines Entwicklers durch objektive und reproduzierbare Kriterien zu ersetzen

und sichert die Objektivität und Reliabilität der Bewertung.

Problematisch bleibt hierbei jedoch die *Referenzierung der realen Szenarien*. Während beispielsweise der Aufwand für die Referenzierung eines Szenarios für die Entwicklung eines ACC-Systems mit der Beobachtung der Bewegung von zwei bis drei Objekten noch überschaubar ist, steigt dieser für die innerstädtische Umfeldwahrnehmung merklich an. Zum Teil steht geeignete Referenzsensorik zum aktuellen Zeitpunkt nicht zur Verfügung, teilweise ist der notwendige Aufwand enorm. Dies hängt zum einen mit der großen Anzahl von Verkehrsteilnehmern unterschiedlichster Gattungen (Fahrzeuge, Fußgänger, Radfahrer, Motorradfahrer) und zum anderen mit den zahlreichen anderen Objekten in den Sichtbereichen der Sensoren (Häuser, Büsche, Schilder, Lichtsignalanlagen, etc.) zusammen. Mittelfristig liegt die Herausforderung in der Entwicklung geeigneter Referenzsensorik für die komplette Referenzierung solcher Szenarien. Kurzfristig wird es darum gehen, mit vorhandener Sensorik die für die Bewertung der Funktion relevanten Informationen aus der Umgebung zu referenzieren und somit eine objektive Bewertung der Algorithmen zu ermöglichen.

Auf Grund der *heterogenen Sensorlandschaft bei den aktiven Sensoren* ist es nahezu unmöglich, Algorithmen unabhängig von der Sensorik in realen Szenarien zu bewerten. Entscheidend ist daher die Bewertung des Gesamtsystems der maschinellen Umfelderkennung (bestehend aus Sensorik und nachgelagerten Algorithmen). Die Performance aktiver Sensorik weist starke Abhängigkeiten von der detaillierten Ausprägung der Szenarien (z. B. Lagewinkel der Objekte) und der physikalischen Oberflächeneigenschaften der Objekte auf. Überdies ist die Sensorperformance mitunter von Umwelteinflüssen abhängig, diese gehören folglich zur Bewertung. Dies wirkt sich auf Grund der erhöhten Anzahl von Parametern negativ auf Objektivität und Reliabilität von Messdatenerhebungen und deren Auswertungen aus.

4 Technischer Lösungsansatz: Urbanes Objekttracking im Kontext hybrider Umfeldmodelle

Der Einsatz maschineller Wahrnehmungssysteme in urbanen Umgebungen stellt hohe Anforderungen an Sensorik und Algorithmen. Die Anforderungen an das System stehen im Konflikt zu den durch die Sensorik lieferbaren Informationen, die Güte des Systemes im Konflikt zur verfügbaren Rechenzeit. Um dennoch den *Anforderungen komplexer Einsatzgebiete* (wie zum Beispiel des urbanen Umfeldes) gerecht zu werden, stehen aktuell unter anderem hybride Umfeldmodelle im Fokus zahlreicher Forschungsaktivitäten (vgl. Abschnitt 2.3.2 und 2.3.3). Hybride Umfeldmodelle schaffen auch für den Schwerpunkt dieser Arbeit, das Objekttracking, neue Möglichkeiten und Potenziale. Diese werden in diesem Kapitel identifiziert und beschrieben. Zuvor werden die Grundlagen hybrider Umfeldmodelle (Abschnitt 4.1) und ihrer einzelnen Module (Abschnitt 4.1.4 bis 4.1.1) beschrieben, um die Erweiterungen des Objekttrackings zu motivieren (vgl. Bild 4.1).




Bild 4.1: Grafische Darstellung der Gliederung von Kapitel 4

4.1 Verwendetes hybrides Umfeldmodell




Bild 4.2: Grafische Darstellung der Gliederung von Kapitel 4.1

Hybride Umfeldmodelle sind eine relativ junge Beschreibungsform für maschinelle Wahrnehmungssysteme im automobilen Kontext (vgl. Effertz 2009). Die grundlegende Idee besteht darin, die Vorteile verschiedener Beschreibungsformen zu fusionieren. Die eingesetzte Gesamtarchitektur, von der Sensordatenerfassung bis zur Funktion des Systemes, wird in Bild 4.3 schematisch dargestellt (vgl. Knaup u. a. 2009). Die eingehenden Sensordaten werden zunächst in einer Bewegungsklassifikation separiert. Die als stationär klassifizierten Daten werden in einer für stationäre Umgebungen optimierten gitterbasierten Darstellungsform verwaltet. Die als beweglich klassifizierten Daten werden in einer für bewegliche Objekte optimierten objektbasierten Darstellungsform verwaltet. In der graphenbasierten Darstellung werden A-Priori-Informationen aus Navigationskarten verarbeitet. Außerdem werden dort die, aus der gitter- und der objektbasierten Darstellungsform, anfallenden Umfeldbeschreibungen unter Einbeziehung der A-Priori-Navigationskartendaten interpretiert. Alle drei Beschreibungsmodelle zusammen werden als hybrides Umfeldmodell bezeichnet und bilden eine konsistente, maschinelle Beschreibung des Umfeldes.

Bild 4.4 zeigt die drei Bestandteile des eingesetzten hybriden Umfeldmodelles am Beispiel einer T-Kreuzung über einem rektifizierten Luftbild. Die gitterbasierte Darstellung wird hierbei beispielhaft für die Darstellung unstrukturierter stationärer Randbebauung genutzt (in der Darstellung wird hierbei zwischen den Hypothesen, dass der Bereich nicht befahrbar ist (rot) und dass der Bereich befahrbar ist (grün) unterschieden). In diesem Beispiel ist ein Ausschnitt einer ortsfesten Gitterstruktur abgebildet. Zudem wird eine objektbasierte Darstellungsform für die Repräsentation beweglicher Objekthypothesen genutzt. Abgebildet ist eine Objekthypothese (cyan blau). Das graphenbasierte Umfeldmodell (gelb) stellt die Verknüpfungen (Knoten) der einzelnen Fahrstreifen (Kanten) der T-Kreuzung dar.

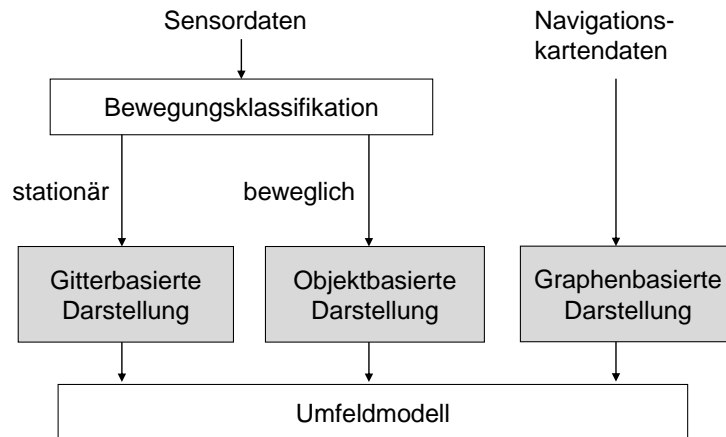


Bild 4.3: Schematische Darstellung des verwendeten Umfeldmodells nach Knaup u. a. 2009.

4.1.1 Bewegungsklassifikation

Gitterbasierte Darstellungsformen sind vornehmlich für stationäre Umgebungen geeignet, dynamische Vorgänge werden nur unscharf abgebildet (vgl. Canas u. Matellan 2006). Objektbasierte Darstellungsformen hingegen sind vor allem geeignet, um dynamische Objekthypothesen darzustellen. Dies macht eine *Zuweisung der eingehenden Sensordaten zu den verschiedenen Darstellungsformen* notwendig. Nach Matthaei u. a. (2011b) und Matthaei u. a. (2011c) wird eine Objekthypothese hierbei als beweglich klassifiziert, wenn sie im Beobachtungszeitraum schon einmal als bewegt detektiert worden ist. Das heißt konkret, dass zuvor bewegte und beispielsweise an der Ampel gestoppte sowie aktuell fahrende Fahrzeuge als beweglich eingestuft werden. Die schon vor dem Beginn der Beobachtung auf einem Parkplatz abgestellten Fahrzeuge, Häuser und Bäume werden als stationär eingestuft (vgl. Matthaei u. a. 2011b und Matthaei u. a. 2011c). Durch die Bewegungsklassifikation erfolgt die Zuweisung zu der objektbasierten (bewegliche Objekthypothesen) und der gitterbasierten (stationäre Randbebauungshypothesen) Darstellung (vgl. Bild 4.3).

4.1.2 Gitterbasiertes Umfeldmodell

Gitterbasierte Umfeldmodelle sind eine verbreitete Beschreibungsform für stationäre Umgebungen. Hierbei wird eine Ebene z. B. in *zweidimensionale Zellen* unterteilt. Ein z. B. in Ohl u. a. (2011) beschriebenes Konzept ermöglicht es, mehrere Ebenen gitterbasierter Umfeldmodelle (Layer) parallel zu betreiben und gegebenenfalls zu fusionieren. Die meisten gitterbasierten Umfeldmodelle sind für die Beschreibung oder die Verwaltung dynamischer Vorgänge ungeeignet (vgl. Canas u. Matellan 2006). Dynamische Bewegungen sorgen für unscharfe Verwischungen innerhalb der Gitterstruktur. Daher werden bewegte Objekte in der




Bild 4.4: Beispielhafte Darstellung des verwendeten hybriden Umfeldmodelles über einem rektifizierten Luftbild ¹.

dieser Arbeit zu Grunde liegenden Architektur durch eine, für bewegte Objekthypothesen optimierte, objektbasierte Beschreibungsform verwaltet.

Bild 4.5 zeigt die Anwendung eines gitterbasierten Umfeldmodelles für eine frei-belegt Darstellung. Schematisch ist hier die Entstehung für einen Strahlsensor (z. B. einen Laserscanner) dargestellt. Oben rechts wird beispielhaft ein reales Objekt durch den Sensor detektiert. Bis zur Objekthypothese werden die Zellen mit einer Frei-Information und die von der Objekthypothese belegten Zellen werden mit einer Belegt-Information aktualisiert. So entsteht im gitterbasierten Umfeldmodell eine maschinelle Repräsentation des Umfeldes in freien und belegten Zellen.

Bild 4.6 zeigt eine zusätzliche Ebene der gitterbasierten Darstellung. Nach Matthaei u. a. (2011a) werden Geschwindigkeitsinformationen in einem gitterbasierten Umfeldmodell akkumuliert. Die grundlegende Idee besteht darin, Geschwindigkeiten bisher gesehener Objekthypothesen zu verwalten und so eine Geschwindigkeitshistorie der in der Vergangenheit detektierten Objekthypothesen zu erhalten. Dabei werden nach Matthaei u. a. (2011a) in Zellen, die auf der Fahrspur einer Objekthypothese liegen, der Geschwindigkeitsvektor und ein Maß für die Verlässlichkeit der Information gespeichert, diese wird beispielsweise bei

¹Kartengrundlage: Orthophotomosaik 1000 der Stadt Wolfsburg, Geschäftsbereich IT - 15-3 GIS, 2008.




Bild 4.5: Schematische frei-belegt-Darstellung in einem gitterbasierten Umfeldmodell für einen strahlbasierten Sensor (z. B. Laserscanner, vgl. Ohl u. a. 2011).




Bild 4.6: Schematische Darstellung einer gitterbasierten Akkumulation der Geschwindigkeit einer detektierten Objekthypothese.

Laserscannern zur Objektinitialisierung genutzt (vgl. Abschnitt 4.3).

4.1.3 Objektbasiertes Umfeldmodell

Im Folgenden wird ein Extended-Kalman-Filter zur Zustandsschätzung der Objekthypothesen verwendet (vgl. Abschnitt 2.2.4). Die Wahl der beim Extended-Kalman-Filter zu bestimmenden Design-Parameter und Modelle wird in Abschnitt 2.2.1 beschrieben.

Durch die Bewegungsklassifikation wird die Anzahl der Objekthypothesen im Tracking verringert. Dies ermöglicht auch im urbanen Umfeld den echtzeitfähigen Einsatz aufwändiger und damit rechenintensiverer Filterverfahren. Da unimodale Filter die verschiedenen, häufig wechselnden Dynamiksituationen im urbanen Umfeld nicht abbilden können, werden in diesem Kontext Multi-Modell-Filter eingesetzt (vgl. Abschnitt 2.2.5). Für die konkrete

Umsetzung werden drei Dynamikmodelle genutzt. Ein Modell konstanter Geschwindigkeit und zwei Modelle konstanter Kurvenfahrt (Links- und Rechtsabbiegen). Die Synchronität der einzelnen Modelle wird über Synchronisationspunkte sichergestellt: Der Objektinitialisierung und der Objekteliminierung. Aus Messungen werden nur neue Objekthypothesen initialisiert, wenn die Messung zuvor in keinem der Modelle assoziiert wurde. Objekthypothesen werden nur aus dem Umfeldmodell entfernt, wenn die Objekthypothese in allen drei Umfeldmodellen zur Entfernung markiert worden ist.

Zur Assoziation wird ein Global-Nearest-Neighbour-Verfahren gewählt (vgl. Karlsson 2002, Blackman 2004, Darms 2007 und Kapp 2007). Dies ist auf Grund des im Vergleich zu den Objektabständen geringen Messrauschens des eingesetzten Sensors ausreichend. Es bietet somit einen Kompromiss zwischen dem notwendigen Aufwand und den erzielten Ergebnissen (vgl. Stüker 2004 und Kapp 2007).

Segmentierung im Kontext hybrider Umfeldmodelle

Dieser Abschnitt beschreibt ein Verfahren zur Gruppierung von Laserpunktwolken in Segmente bzw. Cluster. Dies ist notwendig, da Lasersensoren bei ausgedehnten Zielen mehrere Messungen pro realem Objekt liefern. Nachfolgende Algorithmen benötigen zur Schätzung der Ausdehnung des Objektes jedoch die Informationen, welche Messungen diesem Objekt zugeordnet sind. Verfahren, die dieses leisten, werden Segmentierung genannt und stellen einen wichtigen Schritt der Vorverarbeitung von Laserscannerdaten dar. Aufgabe der Segmentierung ist es, alle Beobachtungen, die von einem realen Objekt verursacht worden sind, zusammenzufassen und Beobachtungen, die von unterschiedlichen realen Objekten verursacht worden sind, zu trennen (vgl. Dietmayer u. a. 2001 und Doth 2009). Im urbanen Umfeld treten bei der Segmentierung von Messungen strahlbasierter Sensoren, die keine Information über die Geschwindigkeit liefern, Mehrdeutigkeiten auf. Dies ist z. B. bei Laserscannern der Fall. Eine beispielhafte Situation wird in Bild 4.7 dargestellt. Eine Objekthypothese bewegt sich hier dicht an einer stationären Objekthypothese vorbei. Klassische Segmentierungsverfahren, die lediglich auf einer Analyse der Sensordaten des aktuellen Messzykluses basieren, können diese Situation prinzipbedingt nicht auflösen.

Zur Auflösung der in Bild 4.7 beschriebenen Mehrdeutigkeit schlägt Matthaei u. a. (2011a) eine Segmentierung vor, die *Informationen aus einer gitterbasierten Geschwindigkeitshistorie* (vgl. Bild 4.6) in die Entscheidungsfindung mit einbezieht. Die Idee besteht darin, neben dem Abstand weitere Merkmale, wie z. B. die in einer gitterbasierten Darstellung akkumulierten Geschwindigkeiten für die Segmentierungsentscheidung zu nutzen, um Mehrdeutigkeiten




Bild 4.7: Schematische Darstellung einer Situation, die durch eine rein abstands-basierte Segmentierung von Entfernungs-Messungen nicht aufgelöst wird.

aufzulösen und auf diese Weise Situationen, wie in Bild 4.7 dargestellt, korrekt zu segmentieren. Dieser in Matthaei u. a. (2011a) vorgestellte Ansatz wird im Rahmen dieser Arbeit verwendet.

4.1.4 Graphenbasiertes Umfeldmodell

Knaup u. a. (2009), Knaup u. Homeier (2010) und Homeier u. Wolf (2011) interpretieren ein graphenbasiertes Umfeldmodell als eine fahrstreifen-genaue Beschreibungsform für A-Priori-Informationen aus Navigationskartendaten. Das graphenbasierte Umfeldmodell stellt die Information aus Navigationsdaten in Form von Knoten und Kanten dar. Kanten und Knoten enthalten hierbei zusätzliche Attribute, dies sind z. B. Daten aus Verkehrszählungen, die zulässige Höchstgeschwindigkeit, geltende Verkehrsregeln, Fahrstreifenbreite und die Position von Schildern oder Lichtsignalanlagen. Beispielhaft ist in Bild 4.8 eine T-Kreuzung im graphenbasierten Umfeldmodell schematisch dargestellt.




Bild 4.8: Schematische Darstellung einer Kreuzung in einem graphenbasierten Umfeldmodell.

Das graphenbasierte Umfeldmodell wird vor allem zur Verbesserung des Szenenverständnisses verwendet (vgl. Knaup u. a. 2009, Knaup u. Homeier 2010, Homeier u. Wolf 2011). Die im graphenbasierten Umfeldmodell vorhandenen, A-Priori-Informationen werden um zusätzliche dynamische Informationen aus den Sensordaten ergänzt.

4.2 Messmodell und daraus abgeleitetes Objektmodell

Mess- und Objektmodelle werden im Kontext hybrider Umfeldmodelle mit veränderten Anforderungen konfrontiert (vgl. Abschnitt 4.2.1). Zusätzlich weist das Messmodell Abhängigkeiten bezüglich der verwendeten Sensorik und deren Eigenschaften auf. Dies macht es notwendig, speziell auf die Sensorik (Abschnitt 2.2.2) und die Anforderungen (Abschnitt 4.2.1) abgestimmte Mess-, Objekt- und Sensormodelle (Abschnitte 4.2.2 bis 4.2.5) zu entwickeln. Die Abschnitte 4.2.6 bis 4.2.9 beschreiben die zusätzlichen Design-Parameter des Interacting-Multi-Model Filters, die verwendeten Dynamikmodelle, die nachträgliche Konturschätzung und die Objekthypotheseninitialisierung (vgl. Bild 4.9).




Bild 4.9: Grafische Darstellung der Gliederung von Kapitel 4.2

4.2.1 Technische Anforderungen

Durch das urbane Umfeld und den Einsatz im Kontext eines hybriden Umfeldmodelles werden an Mess- und Objektmodelle folgende Anforderungen gestellt:

- Im Gegensatz zu den z. B. in Rauskolb u. a. (2008), Effertz (2009) und Ohl u. Maurer (2011b) vorgestellten Ansätzen sind im, in dieser Arbeit verwendeten, hybriden Umfeldmodell keine Objektmodelle für unstrukturierte Randbebauung mehr vorzuhalten. Es besteht daher die Möglichkeit, das Objektmodell für bewegliche Objekte zu optimieren (vgl. Abschnitt 2.3.2).

- An Mess- und Objektmodelle besteht die Forderung, Längs- und Querverkehr zu beherrschen.
- Im urbanen Umfeld sind eine Vielzahl verschiedener Verkehrsteilnehmer vertreten, an die Mess- und Objektmodelle besteht daher der Anspruch, für unterschiedliche Verkehrsteilnehmer (z. B. LKW, PKW, Busse und Radfahrer) geeignet zu sein.
- Wie in Abschnitt 2.3.2 anhand zweier Bilder motiviert, weisen auch Verkehrsteilnehmer gleicher Gattung, z. B. PKW, stark unterschiedliche Konturformen auf. Von Mess- und Objektmodellen wird verlangt, für unterschiedliche Konturformen geeignet zu sein.
- Auf Grund der geringen Reaktionszeiten im urbanen Umfeld wird von den Objektmodellen verlangt, eine geringe Latenz der Filter zu unterstützen. Kämpchen (2007) unterscheidet hierbei zwischen Objektdetektionslatenz (Zeitspanne von der ersten Messung bis zur Initialisierung einer Objekthypothese) und der Latenz der Zustandsschätzung (Zeitspanne zwischen der ersten Messung einer Zustandsänderung bis zur Änderung in der Zustandsschätzung).

4.2.2 Messmodell

Das Messmodell überführt die segmentierten Rohdaten (aus den Basismerkmalen (Rohdaten) durch die Segmentierung entstehende komplexere Merkmale) in die im Umfeldmodell genutzten Merkmale (vgl. Abschnitt 2.2.1). Das Messmodell ist von den Eigenschaften der zu Grunde liegenden Sensorik abhängig. Daher kann das hier vorgeschlagene Messmodell nicht ohne weitergehende Untersuchungen auf andere Sensoren mit einem ähnlichen Messprinzip oder auf Sensoren mit einem anderen Messprinzip angewandt werden. Der eingesetzte Sensor misst Winkel und Entfernungen. Zur Bestimmung der abstrahierten Merkmale wird zunächst der durch die Objekthypothese belegte Winkelbereich ermittelt. Dieser wird durch die eingesetzte Sensorik mit einer hohen Güte bestimmt und durch die begrenzenden Winkel links und rechts beschrieben (vgl. Bild 4.10). Des Weiteren wird die dichteste Entfernung der Objekthypothese bestimmt, hierbei wird aus allen Entfernungsschätzungen, die zwischen dem linken und dem rechten Winkel liegen, die minimale Entfernung bestimmt (vgl. Bild 4.10). Eine laterale Bewegung des Objektes resultiert somit in einer Verschiebung des belegten Winkelsegments, eine longitudinale Bewegung resultiert in einer Änderung der Entfernung.




Bild 4.10: Beschreibung des verwendeten Messmodelles

Für Fahrzeuge basiert die Schätzung der Entfernung in den meisten Fällen auf durch Retroreflektoren verursachten Reflexionen an den Fahrzeugecken. Dies ist darauf zurückzuführen, dass Retroreflektoren auch Laserstrahlen besonders gut reflektieren. Des Weiteren sind Retroreflektoren gesetzlich vorgeschrieben und daher an jedem Fahrzeug vorhanden. Laut Straßenverkehrs-Zulassungs-Ordnung (StVZO) sind in Deutschland nach §53 im Heckbereich des Fahrzeuges mindestens zwei rote Retroreflektoren vorgeschrieben. Diese dürfen nicht mehr als 400mm von der äußeren Fahrzeugkontur und nicht mehr als 900mm von der Fahrbahnebene entfernt angebracht sein. Für Schluss- und Bremsleuchten gilt zusätzlich noch, dass diese nicht tiefer als 350mm über der Fahrbahnebene angebracht werden dürfen. Nach §51 sind auch im vorderen Bereich Begrenzungsleuchten und Scheinwerfer vorgeschrieben. Auch diese dürfen nicht mehr als 400mm von der äußeren Fahrzeugkontur entfernt angebracht werden. Für andere Verkehrsteilnehmer gelten zusätzlich noch ergänzende Vorschriften. Kämpchen (2007) konnte zeigen, dass Messungen von Retroreflektoren (Kennzeichen und Reflektoren der Fahrzeugbeleuchtung) bei Lasersensorik geeigneter als andere Messungen sind, um z. B. den Lagewinkel eines Fahrzeuges zu schätzen. Dies kann auch theoretisch motiviert werden: Abschnitt 2.2.2 beschreibt die Unsicherheit des Reflexionsursprunges beim Auftreffen des Laserstrahles auf eine nicht orthogonal zum Sensor ausgerichtete Fläche. Befindet sich auf dieser Fläche ein Retroreflektor, so wird mit einer erhöhten Wahrscheinlichkeit davon ausgegangen, dass sich dort der Reflexionsursprung befindet (Entscheidung anhand der Amplitude der Reflexion (vgl. Abschnitt 4.2.2)). Auch die begrenzenden Winkel sind gut und stabil zu erkennen, da hier bei Fahrzeugen Reflektoren angebracht sind, die von Laserscannern besonders gut und stabil detektiert werden. Das vorgeschlagene Messmodell hat darüber hinaus den Vorteil, dass keinerlei Modellannahmen über die Kontur oder Klasse

des Objektes, bzw. Fallunterscheidungen bezüglich der Ansicht (Quer- oder Längsverkehr) notwendig sind. Auf das frühzeitige und möglicherweise fehleranfällige Einbringen von Modellwissen wird somit verzichtet. Für den Fall, dass sich *zwei Seiten im Sichtbereich des Sensors* befinden (vgl. Bild 4.10, linkes Beispiel) wird eine Detektion des rechten Winkels vorgenommen. Wird ein rechter Winkel detektiert, so wird nur die dem Sensor zugewandte Seite betrachtet. Dies vereinfacht die Objektmodellierung und verhindert auf einfache und robuste Weise eine Veränderung des Schwerpunktes und damit auch der Geschwindigkeit durch einen Perspektivwechsel. Für die Detektion des Winkels werden ausgehend vom Punkt mit der geringsten Entfernung über Ausgleichsgeraden zwei Vektoren \mathbf{a} und \mathbf{b} gebildet (vgl. Bild 4.11). Mit Hilfe des Skalarproduktes ergibt sich damit:

$$\alpha = \angle(\mathbf{a}, \mathbf{b}) = \arccos\left(\frac{\mathbf{a} \cdot \mathbf{b}}{\|\mathbf{a}\| \|\mathbf{b}\|}\right) \quad (4.1)$$

Durch einen Vergleich von α mit einem oberen und einem unteren Schwellwert wird ein rech-




Bild 4.11: Detektion des rechten Winkels bei einer Objekthypothese mit zwei Seiten (L-Ansicht) im Sichtbereich des Sensors.

ter Winkel ermittelt. Eine Verwendung der Information über die zweite Seite erscheint nicht sinnvoll, da auf Grund der Strahlaufweitung (1°) und der Totalreflexion in der Praxis bei Fahrzeugen nur maximal eine Entfernungsschätzung von dieser Seite stammt. Ferner springt diese Entfernungsschätzung auf Grund von Kantenfehlern (vgl. Abschnitt 2.2.2) merklich. Da diese Fehler nicht stochastischen Ursprungs sind und sich auch nur sehr eingeschränkt präzisieren lassen, würde diese Eigenschaft des Sensors im weiteren Verlauf des Filterprozesses zu inkonsistenten Zuständen führen. Beim vorgestellten Messmodell resultiert eine laterale Bewegung des Objektes in einer Verschiebung des belegten Winkelsegmentes, eine longitudinale Bewegung resultiert in einer Änderung der geschätzten Entfernung. Aus dem vorgestellten

Messmodell ergibt sich folgender Messvektor (\mathbf{z}):

$$\mathbf{z} = \begin{pmatrix} \alpha_{left} \\ \alpha_{right} \\ r \end{pmatrix} \quad (4.2)$$

Messrauschen

Das Messrauschen beschreibt die Unsicherheit der Messung. Abschnitt 2.2.2 motiviert theoretisch, dass die Messunsicherheit unter anderem von der Situation abhängig ist. Somit ist das konkrete Messrauschen unbekannt und wird daher anhand zusätzlicher Merkmale abgeschätzt. Die Feststellung in Kämpchen (2007), dass insbesondere Messungen, die von Retroreflektoren verursacht sind, sich als besonders zuverlässig erweisen, wird hierfür weiterentwickelt. Die Idee besteht darin, dass eine Messung mit einer großen Amplitude mit hoher Wahrscheinlichkeit von einem Retroreflektor verursacht worden ist (vgl. Abschnitt 4.2.2). Eine solche Messung geht mit einem höheren Vertrauen in den Filterprozess ein, als eine Messung mit einer kleinen Amplitude. Der Übergang ist hierbei fließend, es findet eine Adaption über einen nichtlinearen Zusammenhang statt. Hierfür wird zunächst der maximale Fehler durch den Aspektwinkel (vgl. Abschnitt 2.2.2) abgeschätzt. Anschließend wird, aus Messreihen motiviert, ein maximaler Aspektwinkel von 80° angenommen, bei größeren Winkeln setzt erwartungsgemäß Totalreflexion ein.

$$\Delta_r \approx 150m * 2 \cdot \sin\left(\frac{1^\circ}{2}\right) * \tan(80^\circ) \approx 14,85m \quad (4.3)$$

Damit dieser Wert innerhalb der 2σ Region liegt wird $\sigma_r^{max} = 7,5m$ als obere Abschätzung des maximalen Fehlers gewählt. Für einen orthogonal zum Sensor ausgerichteten Retroreflektor beträgt die minimale Unsicherheit $\sigma_r^{min} = 0,47m$ (vgl. Abschnitt 2.2.2). Diese resultiert durch den Informationsverlust bei der Diskretisierung. Die Amplitudeninformation des Sensors nimmt Werte zwischen $a \in [0, 15]$ mit $a \in \mathbb{N}$ an. Damit ergibt sich für die Abschätzung von $\sigma_r = f(a)$ unter der Vermeidung einer Division durch 0 der in Bild 4.12 dargestellte nichtlineare Zusammenhang. Da notwendige Merkmale zur präzisen Bestimmung der Messunsicherheit, wie z. B. die gemessene Echopulsbreite, vom eingesetzten Sensorsystem nicht zur Verfügung gestellt werden, erfolgt lediglich eine Abschätzung:

$$\sigma_r = \frac{\sigma_r^{max}}{(a + 1)} \quad (4.4)$$

$\sigma_{\alpha, left}$ und $\sigma_{\alpha, right}$ ergeben sich gemäß Abschnitt 2.2.2 wie folgt:




Bild 4.12: Abgeschätzter Zusammenhang zwischen Unsicherheit der Entfernungsschätzung des Sensors und der gemessenen Amplitude bei einem Aspektwinkel von 80° .

$$\sigma_\alpha = \sqrt{\frac{1}{12}} 1^\circ \quad (4.5)$$

4.2.3 Objektmodell

In diesem Abschnitt wird ein Objektmodell vorgestellt, welches auf dem in Abschnitt 4.2 vorgestellten Messmodell und den Eigenschaften der eingesetzten Sensorik basiert. Objektmodelle werden notwendig, sobald die Ausdehnung der Objekte deutlich größer als der Abstand zwischen den Objekten wird. Da z. B. PKW mit einer Länge von etwa 5m häufig in einem Abstand kleiner 1m aneinander vorbeifahren, sind Objektmodelle für die urbane Umfeldwahrnehmung erforderlich. Objektmodelle beschreiben beispielsweise ein reales Fahrzeug in abstrakten Zustandsgrößen (z. B. Position, Geschwindigkeit und Ausdehnung). Durch das Messmodell wird ein belegtes Winkelsegment ausgedrückt (vgl. 4.2.2). Die Objekthypothesen werden durch einen Mittelpunkt (x, y) und den Durchmesser (d) dargestellt. Der Parameter d ist hierbei immer der orthogonale Durchmesser des durch die Objekthypothese belegten Winkelsegmentes, auf eine Ausrichtungsschätzung wird zu diesem Zeitpunkt verzichtet. Die Vorteile des vorgestellten Objektmodells liegen in der geringen Komplexität. Weiterhin ist dieses Modell für Längs- und für Querverkehr geeignet, somit wird auf eine frühzeitige und eventuell fehleranfällige Fallunterscheidung verzichtet (vgl. Bild 4.10). Ein weiterer Vorteil liegt darin, dass auf die Annahme, Fahrzeuge seien rechteckig, verzichtet wird (vgl. Bild 4.10, linkes Beispiel). Zudem ist der Zustandsvektor über den gesamten Sensorsichtbereich beobachtbar (die Definition der Beobachtbarkeit findet sich z. B. in Stüker 2004). Die laterale

Geschwindigkeit eines Objektes bzgl. des Ego-Fahrzeuges ergibt sich im Filterprozess über die Winkeländerung des belegten Segmentes. Die longitudinale Geschwindigkeitskomponente ergibt sich aus der Änderung der Entfernung. Aus dem vorgestellten Objektmodell ergibt sich für die geometrische Beschreibung der Objekthypothese folgender Teil des Objektzustandsvektors:

- Position x, y des Schwerpunktes der Kante
- Breite d




Bild 4.13: Beschreibung des verwendeten Objektmodelles

Beispiele und Grenzen

Bild 4.14 analysiert die Eigenschaften des Objektmodelles anhand einiger Beispielszenarien. Für Längs- und Querverkehr repräsentiert das vereinfachte Objektmodell eine Seite der tatsächlichen Kontur des Objektes (vgl. Bild 4.14, oben links und oben rechts). Für abbiegenden Verkehr hingegen repräsentiert das vereinfachte Objektmodell nicht die Kontur des Objektes (vgl. Bild 4.14, unten links und unten rechts). Eine Übereinstimmung wird erst durch die in Abschnitt 4.2.8 vorgestellte, nachträgliche Konturschätzung hergestellt. Während eines Abbiegevorgangs führt dies zu einer Verschiebung des Referenzpunktes der Objekthypothese auf der tatsächlichen Objektkontur und damit zu einem Fehler in der Geschwindigkeitsschätzung. Dieser Fehler lässt sich beispielsweise für einen PKW wie folgt abschätzen: Bei einem PKW (Länge: 5m, Breite: 2m) wandert der Referenzpunkt der Objekthypothese beim Abbiegevorgang um ca. 2,5m. Bei einer durchschnittlichen Dauer eines Abbiegevorgangs von 3s ergibt sich der systematische Fehler der Geschwindigkeitsschätzung damit zu $0,8 \frac{m}{s}$.




Bild 4.14: Darstellung des Objektmodelles in Beispielszenarien.

4.2.4 Zustandsvektor

Bei der Wahl des Zustandsvektors sind neben den in Abschnitt 4.2.1 formulierten Anforderungen auch die Eigenschaften des Messverfahrens zu berücksichtigen. Als rein *distanzmessendes Verfahren* liefert ein Laserscanner keine Möglichkeit die Geschwindigkeit oder die Beschleunigung direkt zu messen. Im Modell wird daher zunächst an einem Simulationsbeispiel untersucht, welche Auswirkungen die Verwendung der *Beschleunigungskomponente* bei einem distanzmessenden Sensor im Zustandsvektor des Kalman-Filters hat. Es wird die Hypothese untersucht, dass eine zusätzliche Schätzung der Beschleunigung bei einem rein distanzmessenden Verfahren zu einer Verlängerung der *Detektionslatenz und der Totzeit* des Filters führt. Einer geringen Detektionslatenz, bzw. Totzeit kommt auf Grund der geringen

Zeitspannen und der hohen Dynamik im urbanen Umfeld eine besondere Bedeutung zu. Hierfür wird ein einfaches eindimensionales Beispiel genutzt. Modelliert wird ein Sensor, der in eine Raumrichtung Distanzwerte liefert. Diese werden verrauscht und diskretisiert. Anschließend werden die Zustandsgrößen mit Hilfe des Kalman-Filters geschätzt und die tatsächlichen Bewegungsdaten des Objektes mit den Ergebnissen des Filters verglichen. Hierbei werden zwei Szenarien untersucht:

- Szenario 1: Das Objekt bewegt sich mit konstanter Geschwindigkeit.
- Szenario 2: Das Objekt beschleunigt gleichförmig.

Es werden die folgenden zwei Filter miteinander verglichen:

- Filter A enthält im Zustandsvektor keine Beschleunigung. Die Beschleunigung wird als additiver Rauschterm ($a = 1 \frac{m}{s^2}$) im Prozessrauschen berücksichtigt. Es wird ein Geschwindigkeitsmodell mit konstanter Geschwindigkeit verwendet. (Continuous White Noise Acceleration Model, nach Bar-Shalom u. a. 2011, S. 43 ff.).
- Filter B enthält die Beschleunigung im Zustandsvektor. Es wird ein Dynamikmodell unter der Annahme einer konstanten Beschleunigung verwendet. (Continuous Wiener Process Acceleration Model, nach Bar-Shalom u. a. 2011, S. 44 ff.).

Simulationszeit	t_{max}	=	5s
Messwertdiskretisierung	$discr$	=	0,1m
Zykluszeit des Sensors	T	=	0.06s
Standardabweichung des Sensors	σ_d	=	0,3m
Initialisierungsgeschwindigkeit des Objektes	v_0	=	$10 \frac{m}{s}$
Initialisierungsposition des Objektes	x_0	=	5m

Tabelle 4.1: Allgemeine Annahmen der Simulation.

Varianz des Messrauschens	σ_r^2	=	$0,1m^2$
Varianz des Prozessrauschens	σ_q^2	=	$8(\frac{m}{s^2})^2$

Tabelle 4.2: Annahmen für Filter A.

Szenario 1 ist also auf Filter A abgestimmt, Szenario 2 auf Filter B. Für die Simulation werden hierbei die in Tabelle 4.1 beschriebenen allgemeinen Annahmen getroffen. Für Filter A (Zustandsvektor: $[x, v]^T$) werden die in Tabelle 4.2 beschriebenen Annahmen getroffen:

Zur Zustandshypothesen-Initialisierung wird die Methode zur Initialisierung aus einer Distanzmessung nach Bar-Shalom u. a. (2011, S. 155 ff.) verwendet, die Geschwindigkeit wird somit mit $0 \frac{m}{s}$ und folgender Kovarianzmatrix initialisiert (hierbei wird nach Bar-Shalom u. a. (2011, S. 155) eine Standardabweichung gewählt, die der halben anzunehmenden Höchstgeschwindigkeit entspricht ($v_{max} = 70 \frac{km}{h} \approx 20 \frac{m}{s}$)).

$$\mathbf{P}(0|0) = \begin{pmatrix} 1 & 0 \\ 0 & 100 \end{pmatrix} \quad (4.6)$$

Für Filter B (Zustandsvektor: $[x, v, a]^T$) werden die in Tabelle 4.3 beschriebenen Annahmen

$$\begin{array}{ll} \text{Varianz des Messrauschens} & \sigma_r^2 = 0,1m^2 \\ \text{Varianz des Prozessrauschens} & \sigma_q^2 = 1\left(\frac{m}{s^2}\right)^2 \end{array}$$

Tabelle 4.3: Annahmen für Filter B.

getroffen: Die Geschwindigkeit mit $0 \frac{m}{s}$, die initiale Unsicherheit der Geschwindigkeitsschätzung ergibt sich aus $v_{max} = 70 \frac{km}{h} \approx 20 \frac{m}{s}$, für die initiale Unsicherheit der Beschleunigungsschätzung wird $a_{max} = 10 \frac{m}{s^2}$ angenommen:

$$\mathbf{P}(0|0) = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 100 & 0 \\ 0 & 0 & 25 \end{pmatrix} \quad (4.7)$$

Bild 4.15 und Bild 4.16 zeigen, dass das Filter mit einem Zustandsvektor ohne Beschleunigung sowohl im Szenario 1 (Bewegung mit konstanter Geschwindigkeit) als auch im Szenario 2 (beschleunigte Bewegung) eine geringere Detektionslatenz hat. Sowohl für ein beschleunigtes Objekt (Szenario 2) als auch für ein Objekt mit konstanter Geschwindigkeit (Szenario 1), zeigt ein Filter mit einem *Zustandsvektor ohne Beschleunigung* und einem konstanten Geschwindigkeitsmodell ein verbessertes Einschwingverhalten. Dieses stellt für die innerstädtische Umfeldwahrnehmung ein entscheidendes Kriterium dar. Daher wird ein Zustandsvektor ohne Beschleunigung gewählt. Dies lässt sich auch theoretisch motivieren: So werden für Filter A (Modell ohne Beschleunigung) zwei Entfernungsmessungen benötigt, um eine Geschwindigkeit zu schätzen. Mit der dritten Messung wird diese erste Schätzung bestätigt und die Zustandshypothese wird ausgegeben. Für Filter B (Modell mit Beschleunigung) werden drei Messungen benötigt, um eine erste Schätzung der Beschleunigung vorzunehmen. Mit der vierten Messung wird die erste Schätzung bestätigt, und die Zustandshypothese wird ausgegeben.




Bild 4.15: Geschwindigkeitsschätzung Soll/Ist: Szenario 1 (das Objekt bewegt sich mit konstanter Geschwindigkeit), Vergleich zwischen Filter A (enthält im Zustandsvektor keine Beschleunigung) und Filter B (enthält die Beschleunigung im Zustandsvektor)

Durch die im Vergleich zum Zustandsvektor mit Beschleunigung verringerte Dimension des Zustandsvektors ergibt sich ein geringerer Ressourcenbedarf. Unter anderem werden in den Kalman-Filtern die Kovarianzmatrizen für die Zustandsunsicherheit verwaltet und zyklisch neu berechnet. Der Aufwand für diese Matrix-Operationen skaliert quadratisch mit der Dimension des Zustandsvektors und hat damit erheblichen Einfluss auf den Ressourcenbedarf des Algorithmus.

4.2.5 Sensormodell

Das Sensormodell bildet den mathematischen Zusammenhang zwischen Zustands- und Messvektor (vgl. Bild 2.4). Es bildet somit die Transformationsvorschrift aus dem Zustandsraum in den Messraum. Der Zustands- und der Messvektor seien durch \mathbf{x} und \mathbf{z} wie folgt beschrieben:

$$\mathbf{x} = \begin{pmatrix} x \\ y \\ d \\ v_x \\ v_y \end{pmatrix} \quad (4.8)$$




Bild 4.16: Geschwindigkeitsschätzung Soll/Ist: Szenario 2 (das Objekt beschleunigt gleichförmig), Vergleich zwischen Filter A (enthält im Zustandsvektor keine Beschleunigung) und Filter B (enthält die Beschleunigung im Zustandsvektor)

$$\mathbf{z} = \begin{pmatrix} \alpha_{left} \\ \alpha_{right} \\ r \end{pmatrix} \quad (4.9)$$

Damit ergibt sich für das Sensormodell folgender Zusammenhang:

$$x_{left} = x \quad (4.10)$$

$$y_{left} = y + \frac{d}{2} \quad (4.11)$$

$$x_{right} = x \quad (4.12)$$

$$y_{right} = y - \frac{d}{2} \quad (4.13)$$

$$\alpha_{left} = \arcsin \left(\frac{y_{left}}{\sqrt{(x^2 + y_{left}^2)}} \right) \quad (4.14)$$

$$\alpha_{right} = \arcsin \left(\frac{y_{right}}{\sqrt{(x^2 + y_{right}^2)}} \right) \quad (4.15)$$

$$r = \min \left(\sqrt{(x^2 + y_r^2)} \right), y_r \in \left\{ y - \frac{d}{2}, y + \frac{d}{2} \right\} \subset \mathbb{R} \quad (4.16)$$

4.2.6 Zusätzliche Design-Parameter des Interacting-Multi-Model-Filters

Das IMM-Filter benötigt die *Bestimmung zweier zusätzlicher Design-Parameter*: Den Satz an Dynamikmodellen und die Übergangswahrscheinlichkeiten zwischen den verschiedenen Dynamikmodellen. Die a priori Bestimmung einer einzigen, allgemeingültigen Übergangsmatrix \mathbf{P}_{ij} ist - wie bereits im Abschnitt 2.3.1 motiviert - für urbane Szenarien nicht möglich. Vielmehr bedarf es einer Anpassung der Übergangsmatrix zur Laufzeit. Dies ist notwendig, weil die Übergangswahrscheinlichkeiten eine *starke Situationsabhängigkeit* aufweisen. Befindet sich das Objekt z. B. in der Stadt auf einer Straße ohne Einmündungen, ist ein Wechsel in eines der Abbiegemodelle merklich unwahrscheinlicher als z. B. innerhalb einer Kreuzung. Diese Situationsabhängigkeit ist im klassischen IMM-Filter nicht berücksichtigt (vgl. Kapitel 2.3.1). Aus der Literatur bekannte Ansätze, die eine *Anpassung der Übergangsmatrix zur Laufzeit* ermöglichen, schaffen es bisher nicht, die Situationsabhängigkeit im urbanen Umfeld allgemeingültig zu behandeln (vgl. Kapitel 2.3.1). Daher wird zunächst a priori eine Übergangsmatrix bestimmt, die versucht einen Kompromiss zwischen allen möglichen Situationen zu bilden. Die Übergangsmatrix \mathbf{P}_{ij} wird wie folgt bestimmt:

$$\mathbf{P}_{ij} = \begin{pmatrix} 0.8 & 0.1 & 0.1 \\ 0.19 & 0.8 & 0.01 \\ 0.19 & 0.01 & 0.8 \end{pmatrix} \quad (4.17)$$

Da diese Lösung für die dieser Arbeit zugrundeliegende Aufgabenstellung nicht angemessen ist, wird in Abschnitt 4.4 ein neuartiger Lösungsansatz beschrieben. Dieser ermöglicht eine allgemeingültige, situationsabhängige Anpassung der Übergangsmatrix zur Laufzeit unter der Nutzung einer zusätzlichen Information aus einem graphenbasierten Umfeldmodell.

4.2.7 Dynamikmodelle

Das Dynamikmodell prädiziert aus einem bekannten Zustand den nächsten erwarteten Zustand. Ein Ziel dieser Arbeit ist die Erhöhung der Präzision bei querdynamischen Bewegungen der Objekthypothesen. Daher werden Dynamikmodelle für *Linksabbiegen, Rechtsabbiegen und Geradeausfahren* gewählt. Für alle Modelle wird ein Modell ohne Beschleunigung angenommen, Geschwindigkeitsänderungen werden als Modellunsicherheiten mittels des Prozessrauschens \mathbf{Q} modelliert (Continuous White Noise Acceleration Model, vgl. Bar-Shalom

u. a. 2011, S. 43 ff.):

$$\mathbf{Q} = \begin{pmatrix} \frac{1}{4}T^4\sigma_{ax}^2 & 0 & \frac{1}{2}T^3\sigma_{ax}^2 & 0 & 0 \\ 0 & \frac{1}{4}T^4\sigma_{ay}^2 & 0 & \frac{1}{2}T^3\sigma_{ay}^2 & 0 \\ \frac{1}{2}T^3\sigma_{ax}^2 & 0 & T^2\sigma_{ax}^2 & 0 & 0 \\ 0 & \frac{1}{2}T^3\sigma_{ay}^2 & 0 & T^2\sigma_{ay}^2 & 0 \\ 0 & 0 & 0 & 0 & T^2\sigma_d^2 \end{pmatrix} \quad (4.18)$$

Für das Modell der Geradeausfahrt mit konstanter Geschwindigkeit ergeben sich damit folgende Zusammenhänge, T sei hierbei die Zykluszeit des Systems:

$$x_{pre}(k+1|k) = x(k|k) + T \cdot v_x(k|k) \quad (4.19)$$

$$y_{pre}(k+1|k) = y(k|k) + T \cdot v_y(k|k) \quad (4.20)$$

$$v_{x,pre}(k+1|k) = v_x(k|k) \quad (4.21)$$

$$v_{y,pre}(k+1|k) = v_y(k|k) \quad (4.22)$$

$$d_{pre}(k+1|k) = d(k|k) \quad (4.23)$$

Daraus ergibt sich für die Zustandsübergangsmatrix \mathbf{F} :

$$\mathbf{F} = \begin{pmatrix} 1 & 0 & T & 0 & 0 \\ 0 & 1 & 0 & T & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix} \quad (4.24)$$

Die Abbiegevorgänge in Kreuzungsbereichen werden auf Grund der niedrigen Geschwindigkeiten als Fahrt auf einer Kreisbahn mit konstanter Geschwindigkeit modelliert. Der Kreis hat einen Radius R , Geschwindigkeitsänderungen der Objekthypothese werden mittels des Prozessrauschens modelliert.

Für das Modell mit konstanter Geschwindigkeit 'Linksabbiegen' ergeben sich damit folgende Zusammenhänge, R sei hierbei der Radius der zu durchfahrenden Kurve:

$$x_{pre}(k+1|k) = x(k|k) + T \cdot v_x(k|k) \cdot \cos\left(\frac{T \cdot v}{R}\right) - T \cdot v_y(k|k) \cdot \sin\left(\frac{T \cdot v}{R}\right) \quad (4.25)$$

$$y_{pre}(k+1|k) = y(k|k) + T \cdot v_x(k|k) \cdot \sin\left(\frac{T \cdot v}{R}\right) + T \cdot v_y(k|k) \cdot \cos\left(\frac{T \cdot v}{R}\right) \quad (4.26)$$

$$v_{x,pre}(k+1|k) = v_x(k|k) \cdot \cos\left(\frac{T \cdot v}{R}\right) - v_y(k|k) \cdot \sin\left(\frac{T \cdot v}{R}\right) \quad (4.27)$$




Bild 4.17: Grafische Beschreibung des Dynamikmodelles für die Kurvenfahrt auf einer Kreisbahn mit konstanter Geschwindigkeit.

$$v_{y,pre}(k+1|k) = v_x(k|k) \cdot \sin\left(\frac{T \cdot v}{R}\right) + v_y(k|k) \cdot \cos\left(\frac{T \cdot v}{R}\right) \quad (4.28)$$

$$d_{pre}(k+1|k) = d(k|k) \quad (4.29)$$

Daraus ergibt sich für die Zustandsübergangsmatrix \mathbf{F} :

$$\mathbf{F} = \begin{pmatrix} 1 & 0 & T \cdot \cos\left(\frac{T \cdot v}{R}\right) & -T \cdot \sin\left(\frac{T \cdot v}{R}\right) & 0 \\ 0 & 1 & T \cdot \sin\left(\frac{T \cdot v}{R}\right) & T \cdot \cos\left(\frac{T \cdot v}{R}\right) & 0 \\ 0 & 0 & \cos\left(\frac{T \cdot v}{R}\right) & -\sin\left(\frac{T \cdot v}{R}\right) & 0 \\ 0 & 0 & \sin\left(\frac{T \cdot v}{R}\right) & \cos\left(\frac{T \cdot v}{R}\right) & 0 \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix} \quad (4.30)$$

Für das Modell mit konstanter Geschwindigkeit 'Rechtsabbiegen' ergeben sich damit folgende Zusammenhänge, R sei hierbei der Radius der zu durchfahrenden Kurve, T die Zykluszeit des Systems:

$$x_{pre}(k+1|k) = x(k|k) - T \cdot v_x(k|k) \cdot \cos\left(\frac{T \cdot v}{R}\right) + T \cdot v_y(k|k) \cdot \sin\left(\frac{T \cdot v}{R}\right) \quad (4.31)$$

$$y_{pre}(k+1|k) = y(k|k) - T \cdot v_x(k|k) \cdot \sin\left(\frac{T \cdot v}{R}\right) - T \cdot v_y(k|k) \cdot \cos\left(\frac{T \cdot v}{R}\right) \quad (4.32)$$

$$v_{x,pre}(k+1|k) = -v_x(k|k) \cdot \cos\left(\frac{T \cdot v}{R}\right) + v_y(k|k) \cdot \sin\left(\frac{T \cdot v}{R}\right) \quad (4.33)$$

$$v_{y,pre}(k+1|k) = -v_x(k|k) \cdot \sin\left(\frac{T \cdot v}{R}\right) - v_y(k|k) \cdot \cos\left(\frac{T \cdot v}{R}\right) \quad (4.34)$$

$$d_{pre}(k+1|k) = d(k|k) \quad (4.35)$$

Daraus ergibt sich für die Zustandsübergangsmatrix \mathbf{F} :

$$\mathbf{F} = \begin{pmatrix} 1 & 0 & -T \cdot \cos\left(\frac{T \cdot v}{R}\right) & T \cdot \sin\left(\frac{T \cdot v}{R}\right) & 0 \\ 0 & 1 & -T \cdot \sin\left(\frac{T \cdot v}{R}\right) & -T \cdot \cos\left(\frac{T \cdot v}{R}\right) & 0 \\ 0 & 0 & -\cos\left(\frac{T \cdot v}{R}\right) & \sin\left(\frac{T \cdot v}{R}\right) & 0 \\ 0 & 0 & -\sin\left(\frac{T \cdot v}{R}\right) & -\cos\left(\frac{T \cdot v}{R}\right) & 0 \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix} \quad (4.36)$$

Für die Bestimmung des Radius R der zu durchfahrenden Kurve wird zusätzliches Modellwissen verwendet. Schimmelpfennig u. Nackenhorst (1985) formulieren einen mathematischen Zusammenhang zwischen der Querbeschleunigung und der Geschwindigkeit bei Kurvenfahrten von Normalfahrern:

$$a_q = 0,155 \cdot \frac{v}{\frac{km}{h}} \cdot e^{-\left(\frac{v}{70 \frac{km}{h}}\right)^{1,85}}. \quad (4.37)$$

Der Zusammenhang zwischen Querbeschleunigung und Kurvenradius wird wie folgt beschrieben:

$$a_q = \frac{v^2}{R}. \quad (4.38)$$

Daraus ergibt sich für den Radius R in Abhängigkeit von der Geschwindigkeit v :

$$R = \frac{v^2}{0,155 \cdot \frac{v}{\frac{km}{h}} \cdot e^{-\left(\frac{v}{70 \frac{km}{h}}\right)^{1,85}}} \quad (4.39)$$

Es werden Dynamikmodelle für Linksabbiegen, Rechtsabbiegen und Geradeausfahren implementiert. Für alle Modelle wird ein konstantes Geschwindigkeitsmodell angenommen, die Modelle für das Abbiegen als Fahrt auf einer Kreisbahn mit konstanter Geschwindigkeit modelliert.

Grenzen: Die Veränderung des Durchmessers d während eines Abbiegevorgangs wird über

das Prozessrauschen abgebildet und nicht modelliert. Eine Modellierung der systematischen Veränderung ist aufgrund des nicht geschätzten Lagewinkels der Objekthypothese an dieser Stelle unmöglich.

Prozessrauschen

Das Prozessrauschen für die Dynamikmodelle Links- und Rechtsabbiegen wird wie folgt gewählt: Longitudinal wird ein maximales Beschleunigungs- bzw. Verzögerungsvermögen von $9\frac{m}{s^2}$ angenommen (angenommenes Beschleunigungsvermögen eines Fahrzeugs), die Querbesehleunigung wird ebenfalls mit maximal $9\frac{m}{s^2}$ abgeschätzt. Damit sich die maximalen Werte innerhalb der 3σ Region bewegen, wird $\sigma_{ax} = 3\frac{m}{s^2}$ und $\sigma_{ay} = 3\frac{m}{s^2}$ gewählt. Die Änderung des Querschnitts d bei Kurvenfahrten wird mit $\sigma_d = 2m$ abgeschätzt:

$$\mathbf{Q}_{left}, \mathbf{Q}_{right} = \begin{pmatrix} \frac{1}{4}T^4\sigma_{ax}^2 & 0 & \frac{1}{2}T^3\sigma_{ax}^2 & 0 & 0 \\ 0 & \frac{1}{4}T^4\sigma_{ay}^2 & 0 & \frac{1}{2}T^3\sigma_{ay}^2 & 0 \\ \frac{1}{2}T^3\sigma_{ax}^2 & 0 & T^2\sigma_{ax}^2 & 0 & 0 \\ 0 & \frac{1}{2}T^3\sigma_{ay}^2 & 0 & T^2\sigma_{ay}^2 & 0 \\ 0 & 0 & 0 & 0 & T^2\sigma_d^2 \end{pmatrix} \quad (4.40)$$

Beim Prozessrauschen des Geradeaus-Dynamikmodells wird zwischen einer lateralen und einer longitudinalen Bewegung unterschieden. Diese Unterscheidung wird regelbasiert über den Geschwindigkeitsvektor durchgeführt. Der Wechsel zwischen den Modi findet über einen Abbiegevorgang statt. Das Prozessrauschen für die Dynamikmodelle geradeaus lateral und geradeaus longitudinal wird wie folgt gewählt: Longitudinal wird ein maximales Beschleunigungs- bzw. Verzögerungsvermögen von $9\frac{m}{s^2}$ angenommen, die Querbesehleunigung wird mit maximal $1\frac{m}{s^2}$ abgeschätzt. Damit sich die Werte maximal innerhalb der 3σ Region bewegen, wird $\sigma_{ax} = 3\frac{m}{s^2}$ und $\sigma_{ay} = 1\frac{m}{s^2}$, bzw. $\sigma_{ax} = 1\frac{m}{s^2}$ und $\sigma_{ay} = 3\frac{m}{s^2}$ gewählt. Die Änderung des Querschnitts d wird mit $\sigma_d = 1m$ abgeschätzt:

$$\mathbf{Q}_{straight,long.} = \begin{pmatrix} \frac{1}{4}T^4 \cdot 3\frac{m^2}{s^2} & 0 & \frac{1}{2}T^3 \cdot 3\frac{m^2}{s^2} & 0 & 0 \\ 0 & \frac{1}{4}T^4 \cdot 1\frac{m^2}{s^2} & 0 & \frac{1}{2}T^3 \cdot 1\frac{m^2}{s^2} & 0 \\ \frac{1}{2}T^3 \cdot 3\frac{m^2}{s^2} & 0 & T^2 \cdot 3\frac{m^2}{s^2} & 0 & 0 \\ 0 & \frac{1}{2}T^3 \cdot 1\frac{m^2}{s^2} & 0 & T^2 \cdot 1\frac{m^2}{s^2} & 0 \\ 0 & 0 & 0 & 0 & T^2 \cdot 1m^2 \end{pmatrix} \quad (4.41)$$

$$\mathbf{Q}_{straight,lat.} = \begin{pmatrix} \frac{1}{4}T^4 \cdot 1 \frac{m^2}{s^2} & 0 & \frac{1}{2}T^3 \cdot 1 \frac{m^2}{s^2} & 0 & 0 \\ 0 & \frac{1}{4}T^4 \cdot 3 \frac{m^2}{s^2} & 0 & \frac{1}{2}T^3 \cdot 3 \frac{m^2}{s^2} & 0 \\ \frac{1}{2}T^3 \cdot 1 \frac{m^2}{s^2} & 0 & T^2 \cdot 1 \frac{m^2}{s^2} & 0 & 0 \\ 0 & \frac{1}{2}T^3 \cdot 3 \frac{m^2}{s^2} & 0 & T^2 \cdot 3 \frac{m^2}{s^2} & 0 \\ 0 & 0 & 0 & 0 & T^2 \cdot 1m^2 \end{pmatrix} \quad (4.42)$$

Kompensation der Eigenbewegung

Die Eigenbewegung des mit dem Umfeldwahrnehmungssystem bestückten Fahrzeuges wird durch $\Delta \mathbf{x}_{Ego}$ beschrieben und setzt sich aus den translatorischen Komponenten Δx_{Ego} , Δy_{Ego} sowie der rotatorischen Komponente $\Delta \psi_{Ego}$ zusammen. Es wird das in Stüker (2004) vorgestellte Verfahren zur Kompensation der Eigenbewegung verwendet. Die Prädiktion mittels des Geradeaus-Modelles ergibt sich um die Eigenbewegung bereinigt wie folgt:

$$x_{pre}(k+1|k) = \cos(\Delta \psi) \cdot (x^* - \Delta x) + \sin(\Delta \psi) \cdot (y^* - \Delta y) \quad (4.43)$$

$$y_{pre}(k+1|k) = -\sin(\Delta \psi) \cdot (x^* - \Delta x) + \cos(\Delta \psi) \cdot (y^* - \Delta y) \quad (4.44)$$

$$v_{x,pre}(k+1|k) = v_x(k|k) \quad (4.45)$$

$$v_{y,pre}(k+1|k) = v_y(k|k) \quad (4.46)$$

$$d_{pre}(k+1|k) = d(k|k) \quad (4.47)$$

mit $x^* = x(k|k) + T \cdot v_x(k|k)$ und $y^* = y(k|k) + T \cdot v_y(k|k)$.

4.2.8 Nachträgliche Konturschätzung

Der Zustandsvektor beschreibt die Koordinaten eines Punktojektes mit einer Geschwindigkeit und einer Ausdehnung. Die Ausdehnung hat keine Orientierung im Raum und beschreibt den Durchmesser des durch die Objekthypothese belegten Segmentes. Nachfolgende Algorithmen verlangen jedoch häufig nach einer exakteren Schätzung der Dimension der Objekthypothesen. Diese wird bei diesem Ansatz nachgeordnet durch die Konturschätzung realisiert. Die Konturschätzung nutzt dabei zusätzlich zur Position aus den Sensordaten die zeitliche Information aus dem Tracking. Erst mit Hilfe des Geschwindigkeitsvektors lässt sich ermitteln, welche Seite des Objektes vom Sensor erfasst wurde. Abhängig von der gesehenen Seite wird das Winkelsegment parallel (Querverkehr) oder orthogonal (Längsverkehr) zum Geschwindigkeitsvektor ausgerichtet und in der Länge korrigiert (siehe Bild 4.18).

Zunächst werden der Referenzpunkt und der Punkt mit der geringsten radialen Entfernung regelbasiert ausgewählt (vgl. Tabelle 4.4). Hierbei wird angenommen, dass es sich um ein


$$\hat{\mathbf{x}} = \begin{pmatrix} x \\ y \\ w \\ l \\ \textit{Referenzpunkt} \\ \Psi \\ v_x \\ v_y \end{pmatrix} \quad (4.48)$$

Hierbei ist w die Breite der Objekthypothese, ausgerichtet orthogonal zum Geschwindig-

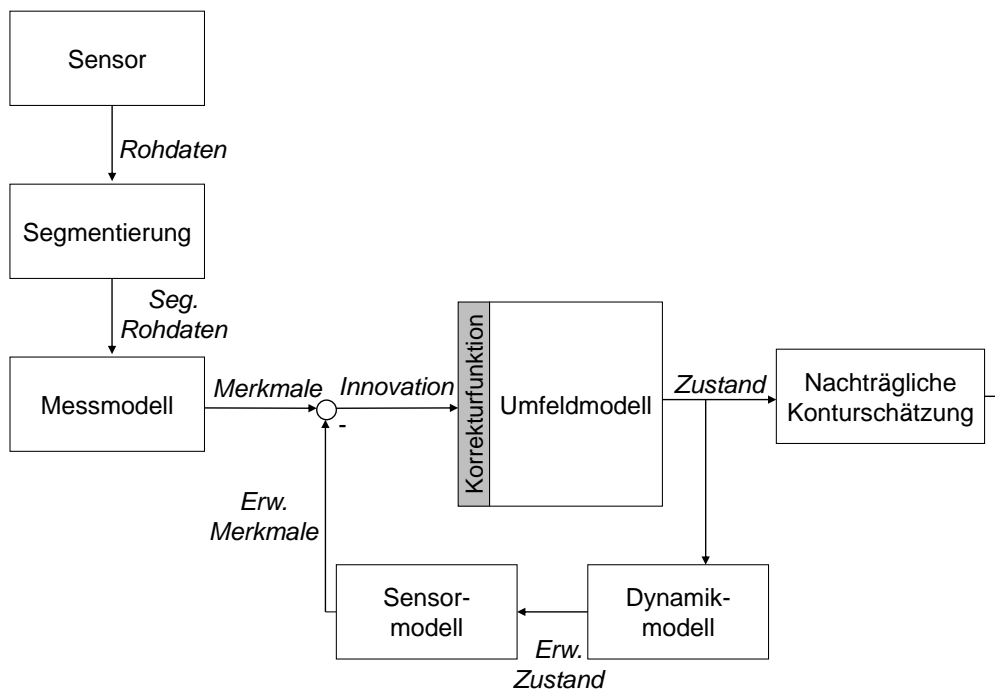


Bild 4.19: Schematische Darstellung, der um eine nachträgliche Konturschätzung erweiterten Modelle, bei der Umfeldmodellierung durch einen rekursiven Filterprozess (vgl. 2.4 und Effertz 2009).

keitsvektor, l die Länge der Objekthypothese, ausgerichtet in Richtung des Geschwindigkeitsvektors, dem Referenzpunkt (Mitte Front, Mitte Heck, Mitte rechts oder Mitte links) und dem Lagewinkel Ψ der Objekthypothese. Die nachträgliche Konturschätzung hat den Vorteil, dass eine wesentliche Information (Geschwindigkeit aus dem Tracking) in die Konturschätzung miteinbezogen werden kann, die zu einem früheren Zeitpunkt in dieser Form nicht zur Verfügung steht. Frühe und fehleranfällige Entscheidungen werden so vermieden. Umgekehrt haben Fehler in der Konturschätzung so keine negative Auswirkung auf den Filter-Algorithmus, weil es sich um ein *rückwirkungsfreies, nachgelagertes Modul* handelt (vgl. Bild 4.19). Des Weiteren ist eine nachträgliche Konturschätzung auch deshalb sinnvoll, da im Kontext des verwendeten hybriden Umfeldmodelles nur bewegliche Objekte in der objektbasierten Darstellung modelliert werden. Eine Geschwindigkeitsinformation ist somit per Definition stets vorhanden. Klassische Konturschätzungen innerhalb des Filterprozesses haben außerdem oft den Nachteil, dass in großen Entfernungen durch die Strahlaufweitung nicht genügend Messdaten zur Verfügung stehen, um aufwändige Konturmodelle zu schätzen. Häufig muss daher dann die Reichweite eingeschränkt werden (vgl. Kämpchen 2007). Das vorgestellte Verfahren auf Basis des Geschwindigkeitssignales bietet daher den Vorteil,

	Referenzpunkt	Dichtester Punkt
$165 \leq (\psi - \alpha) < 195$	Mitte Front	Mitte
$135 \leq (\psi - \alpha) < 165$	Mitte Front	Rechts
$105 \leq (\psi - \alpha) < 135$	Mitte Links	Links
$75 \leq (\psi - \alpha) < 105$	Mitte Links	Mitte
$45 \leq (\psi - \alpha) < 75$	Mitte Links	Rechts
$15 \leq (\psi - \alpha) < 45$	Mitte Hinten	Links
$-15 \leq (\psi - \alpha) < 15$	Mitte Hinten	Mitte
$-45 \leq (\psi - \alpha) < -15$	Mitte Hinten	Rechts
$-75 \leq (\psi - \alpha) < -45$	Mitte Rechts	Links
$-105 \leq (\psi - \alpha) < -75$	Mitte Rechts	Mitte
$-135 \leq (\psi - \alpha) < -105$	Mitte Rechts	Rechts
$-165 \leq (\psi - \alpha) < -135$	Mitte Front	Links

Tabelle 4.4: Regelbasierte Auswahl des Referenzpunktes und des Konturpunktes mit der geringsten radialen Entfernung.

über den *kompletten Sensorsichtbereich* eine Schätzung der Kontur zu ermöglichen.

4.2.9 Objekthypotheseninitialisierung

Zur Zustandshypothesen-Initialisierung wird die Methode zur Initialisierung aus einer Distanzmessung nach Bar-Shalom u. a. (2011, S. 155 ff.) verwendet. Für die initiale Unsicherheit der Geschwindigkeitsschätzung wird eine Standardabweichung in der Größe der Hälfte der maximalen Geschwindigkeit ($v_{max} = 70 \frac{km}{h} \approx 20 \frac{m}{s}$) gewählt. Der maximale Fehler durch den Aspektwinkel wird wie in Abschnitt 2.2.2 beschrieben aus Messreihen motiviert mit 80° angenommen. Bei größeren Winkeln setzt Totalreflexion ein (vgl. Abschnitt 2.2.2).

$$\Delta_r \approx 150m \cdot 2 \cdot \sin(0,5^\circ) \cdot \tan(80^\circ) \approx 14,85m \quad (4.49)$$

Damit dieser Wert innerhalb der 3σ -Region liegt, wird $\sigma_r^{max} = 7,5m$ als obere Abschätzung des maximalen Fehlers gewählt. Daraus ergibt sich folgende initiale Kovarianzmatrix:

$$\mathbf{P}(0|0) = \begin{pmatrix} 14 & 0 & 0 & 0 & 0 \\ 0 & 14 & 0 & 0 & 0 \\ 0 & 0 & 100 & 0 & 0 \\ 0 & 0 & 0 & 100 & 0 \\ 0 & 0 & 0 & 0 & 14 \end{pmatrix} \quad (4.50)$$




Bild 4.20: Schematische Darstellung der Ausgangslage und des regelbasierten Verschiebens bei der nachträglichen Konturschätzung.

4.2.10 Fazit

Die Vorteile des vorgestellten Objektmodells liegen in der geringen Komplexität: Ein einziges Modell ist sowohl für Längs- als auch für Querverkehr geeignet, lediglich das Prozessrauschen wird angepasst. Somit wird auf eine frühzeitige und möglicherweise fehleranfällige Entscheidung verzichtet. Häufig werden bisher in der Beschreibung von Fahrzeugkonturen Rechteckmodelle verwendet. Bei diesen wird angenommen, dass Fahrzeuge eckig sind. Durch aerodynamisch optimierte Bauformen trifft diese Annahme auf immer weniger Fahrzeuge zu. Der vorgestellte Ansatz verzichtet daher auf diese Annahme innerhalb des Filterprozesses. Die Aufgabe der *Konturschätzung* wird stattdessen an ein nachgelagertes Modul übertragen. Dies ermöglicht es zudem, die Kontur nur für eine Auswahl relevanter Objekte zu bestimmen und so die Rechenkomplexität zu minimieren. Durch den reduzierten Zustandsvektor schwingt das Filter schnell ein. Teile dieses Abschnitts sind in Dyckmanns u. a. (2011c) veröffentlicht worden.




Bild 4.21: Schematische Darstellung des Drehens in Richtung des Geschwindigkeitsvektors und der Längen Anpassung bei der nachträglichen Konturschätzung.

4.3 Fusion von objekt- und gitterbasierten Darstellungsformen

Für Assistenz- bzw. Komfortsystem, das eine Reaktion des Fahrers erwarten besteht der Anspruch einer rechtzeitigen Detektion des Objektes vor einer möglichen kritischen Situation, um dem Fahrer nach der erfolgten Warnung noch die Möglichkeit einer Reaktion zu geben. Das bedeutet für ein maschinelles Wahrnehmungssystem im urbanen Umfeld eine möglichst schnelle Initialisierung der Objekthypothesen zu ermöglichen.

4.3.1 Problembeschreibung und abgeleitete Anforderungen

Bei einer Initialisierung mittels einer Entfernungsmessung nach Bar-Shalom u. a. (2011, S. 155 ff.) werden die dynamischen Zustände (wie z. B. die Geschwindigkeit) mangels adäquater Information mit $0 \frac{m}{s}$ initialisiert. Bei einem distanzmessenden Sensor benötigt das Einschwingen der dynamischen Zustände je nach Design des Filters (Vertrauen in die Messung (Messrauschen) vs. Vertrauen in das Modell (Prozessrauschen)) mindestens zwei weitere Messzyklen. Bei einer Initialisierung mittels zweier Entfernungsmessungen nach Bar-Shalom u. a. (2011, S. 154 ff.) werden dynamische Zustände wie z. B. die Geschwindigkeit durch die Differenzierung zweier Entfernungsmessungen initialisiert. Eine Abhilfe könnte hier der

Einsatz eines Geschwindigkeiten messenden Sensors sein. Im Kontext dieser Arbeit wird jedoch nur ein Lasersensor verwendet. Die klassischen Initialisierungsverfahren benötigen mindestens drei Messzyklen für diesen Vorgang. Beim eingesetzten Sensorsystem mit einer Messzykluszeit von 60ms entspricht dies mindestens 180ms.

Ziel ist die Umsetzung einer schnellst möglichen Initialisierung mit einem distanzmessenden Sensor: Es besteht der Anspruch, die Objektdetektionslatenz auf die bei einem distanzmessenden Sensor minimal mögliche Anzahl von zwei Zyklen zu minimieren. Bei einer Zykluszeit von 60ms entspricht dies 120ms. Zwei Zyklen sind mindestens notwendig, um eine initialisierte Geschwindigkeitshypothese zu bestätigen.

4.3.2 Lösungsansatz

Bei der Initialisierung der Objekthypothese wird die Geschwindigkeit unter der Berücksichtigung zusätzlicher Informationen initialisiert. Diese Geschwindigkeit wird mit den beiden ersten Entfernungsmessungen des Sensors bestätigt und die Objekthypothese ausgegeben. Der Messvektor $\mathbf{z}(0)$, der Zustandsvektor $\hat{\mathbf{x}}(0|0)$ und die Messfunktion h stehen in folgendem Zusammenhang (vgl. Stüker 2004):

$$h(\hat{\mathbf{x}}(0|0)) = \mathbf{z}(0). \quad (4.51)$$

Im Gegensatz zu aus der Literatur bekannten Initialisierungsverfahren wird bei diesem neuartigen Ansatz zusätzliche Information aus einer gitterbasierten Umfeldrepräsentation genutzt, um dynamische Zustände zu initialisieren. Hierfür wird die, in den Abschnitten 4.1.2 und 4.1.3 vorgestellte *Akkumulation der Geschwindigkeiten aller Objekthypothesen in einer gitterbasierten Darstellung* genutzt:

$$\hat{\mathbf{x}}(0|0) = g \left(\mathbf{z}(0), \prod_{i,j=1}^{M,N} P[z(i,j)|\hat{\mathbf{x}}_k] \right) \quad (4.52)$$

Die Funktion g sei hierbei die Abbildung von $\mathbf{z}(0)$ und der Information der Geschwindigkeitshistorie $\prod_{i,j=1}^{M,N} P[z(i,j)|\hat{\mathbf{x}}_k]$ auf den Initialen Zustand $\hat{\mathbf{x}}(0|0)$. Hierbei seien M und N die

Anzahl der Zellen in i- und j-Richtung.

$$\hat{\mathbf{x}}(0|0) = \begin{pmatrix} x \\ y \\ d \\ v_x \\ v_y \end{pmatrix} \quad (4.53)$$

Die Zustandsgrößen x und y und der Parameter d werden hierbei geometrisch aus einer Messung $\mathbf{z}(k+1)$ initialisiert. Die Geschwindigkeiten v_x und v_y und die zugehörigen Varianzen σ_{vx}^2 und σ_{vy}^2 werden an der, aus der Messung bestimmten, Position in der Information des gitterbasierten Umfeldmodelles abgefragt und anschließend initialisiert. Hierbei wird angenommen, dass sich eine neu zu initialisierende Objekthypothese ähnlich verhält wie zuvor verfolgte Objekthypothesen. Diese Annahme erscheint auf Grund der Organisation von Straßen und Kreuzungen in Fahrstreifen mit definierten Bewegungsrichtungen gerechtfertigt. Beispielsweise wird davon ausgegangen, dass, wenn auf einem Fahrstreifen ein Fahrzeug entgegengekommen ist, bei weiteren Fahrzeugen auf diesem Fahrstreifen ein ähnliches Verhalten zu erwarten ist. Die Varianzen σ_{vx}^2 und σ_{vy}^2 geben hierbei an, wie vertrauenswürdig die Geschwindigkeitsinformation zum Abfragezeitpunkt ist (vgl. Matthaei u. a. 2011a). Wird die betreffende Zelle durch zwei Objekthypothesen mit ähnlichen Geschwindigkeitsvektoren aktualisiert, so resultiert dies in einer niedrigen Varianz. Sind die Geschwindigkeitsvektoren unterschiedlich, so ist die Information unsicher und resultiert in einer entsprechend hohen Varianz. Liegt für die betreffende Zelle noch keine Information vor, so wird das Objekt wie bisher nach dem in Abschnitt 4.2.9 vorgestellten Verfahren initialisiert. Das heißt, die Geschwindigkeit wird mit $0 \frac{m}{s}$ und einer großen Unsicherheit initialisiert.

4.3.3 Diskussion

Zur schnelleren Initialisierung der Objekthypothesen werden objekt- und gitterbasierte Darstellungsformen fusioniert. Der vorgestellte Ansatz ermöglicht es, im Falle einer vorhandenen Geschwindigkeitsinformation nach zwei Distanzmessungen eine Objekthypothese zu bestätigen und auszugeben. Dies stellt für einen distanzmessenden Sensor die kürzest mögliche Zeitspanne dar. Darüber hinaus ist der vorgestellte Lösungsansatz auf weitere mittelfristig verfügbare Informationsbasen (wie z. B. Extended Floating Car Data (XFCD)) erweiterbar. Diese werden über das gitterbasierte Umfeldmodell für die Verbesserung der Objekthypotheseninitialisierung genutzt. Hierfür werden die Geschwindigkeiten aller Objekthypothesen in einer gitterbasierten Darstellung akkumuliert. Die Geschwindigkeiten werden dabei gewich-

tet (vgl. Bild 4.22, Unterschiedliche Skalierung der Grau-Stufen).



Bild 4.22: Darstellung der Geschwindigkeitshistorie (grau) über einem rektifizierten Luftbild ². Beispielhafter Zustand der Objekthypothesen mit geschätzter Position, geschätztem Geschwindigkeitsvektor und der geschätzten Ausdehnung als graue Rechtecke abgebildet. Geschätzte Position des Ego Fahrzeuges in blau dargestellt.

Das vorgestellte Verfahren hat den Vorteil, dass *keine zusätzliche geschwindigkeitsmessende Sensorik* für eine schnelle Objekthypothesengenerierung nötig ist. Die vorhandenen Informationen werden über die Zeit in einer gitterbasierten Struktur akkumuliert und für die Initialisierung genutzt. Auf diese Weise wird bei der Objektinitialisierung neben der aktuellen Messung zusätzlich noch die Information aus der Historie genutzt. Teile dieses Abschnitts sind in Dyckmanns u. a. (2011c) veröffentlicht worden.

Grenzen: Es ist möglich, dass die initial angenommene Geschwindigkeit falsch ist. Dies führt zu einer Verlängerung des Einschwingvorgangs und ist damit kontraproduktiv. Durch die Organisation von Straßen und Kreuzungen in Fahrstreifen ist dieser Fall in den praktischen Validierungen der Algorithmen nicht aufgetreten, bleibt aber theoretisch möglich. Hier ist z. B. das in Weiß, K. (2006) vorgeschlagene Generalized-Pseudo-Baysian Filter (GPB)

²Kartengrundlage: Orthophotomosaik 1000 der Stadt Wolfsburg, Geschäftsbereich IT - 15-3 GIS, 2008.

eine Alternative. Hierbei werden drei unterschiedliche Geschwindigkeitshypothesen initialisiert. Nach den ersten beiden Messungen wird aus diesen anhand der Modellwahrscheinlichkeiten eine Zustandshypothese gebildet. Das GBP Filter wird nach diesen zwei Messungen verworfen und nur die gemeinsame Zustandshypothese für die weiteren Filterschritte genutzt.

4.4 Fusion von objekt- und graphenbasierten Darstellungsformen

Weil unimodale Filter den häufig wechselnden Dynamikzuständen in urbanen Kreuzungsbereichen nicht gewachsen sind, haben sich sogenannte Multi-Modell-Filter zur Lösung dieser Problemstellung etabliert. Die effizienteste und am weitesten verbreitete Form ist das IMM-Filter. Dieses Filter hat im Vergleich zu unimodalen Filtern zwei zusätzliche Design-Parameter: Die Auswahl der verwendeten Dynamikmodelle und die Übergangswahrscheinlichkeiten zwischen den verschiedenen Modellen. Dieser Abschnitt widmet sich der situationsadaptiven Bestimmung der Übergangswahrscheinlichkeiten zur Laufzeit.

4.4.1 Problembeschreibung und abgeleitete Anforderungen

Während die Anzahl der Modelle noch physikalisch motiviert werden kann, stellt die Modellierung der a priori zu bestimmende Übergangsmatrix, die die Übergangswahrscheinlichkeiten zwischen den verschiedenen Modellen beschreibt, wie in Abschnitt 2.3.1 beschrieben eine besondere Herausforderung dar. Die Übergangswahrscheinlichkeiten zwischen den verschiedenen Modellen sind je nach Ort und Verkehrssituation stark unterschiedlich und können a priori in der Praxis nicht für jede Situation angegeben werden. Es fehlt bisher ein Lösungsansatz der eine allgemeingültige Lösung der Orts- und Situationsabhängigkeit der Übergangsmatrix gewährleistet. Ferner besteht der Anspruch, dass der Algorithmus echtzeitfähig ist. Dies bedeutet, die Berechenbarkeit innerhalb eines Messzyklus (60ms) muss möglich sein.

4.4.2 Lösungsansatz

Schubert u. Wanielik (2009) (vgl. Abschnitt 2.3.1) schlagen eine Adaption der Übergangsmatrix zur Laufzeit mittels eines Bayes'schen Netzes vor. Da komplexe Bayes'sche Netze nur sehr schwer auf Korrektheit zu prüfen sind, wird in diesem Kontext eine deterministische Erweiterung zur Adaption der Übergangsmatrix vorgeschlagen. Informationen über Fahrstreifenverläufe aus Navigationskartendaten liefern sehr eindeutige und sichere Evidenzen über das Verhalten der Objekthypothesen. Auf eine Darstellung von unsicheren Informationen mittels eines Bayes'schen Netzes wird daher auch aus diesem Grund verzichtet und

stattdessen ein alternativer Ansatz gewählt und im Folgenden vorgestellt.

Die Idee besteht darin, die Übergangsmatrix über zusätzliche A-Priori-Informationen aus dem graphenbasierten Umfeldmodell zur Laufzeit zu adaptieren. Diese erweiterte Informationsbasis wird hierbei zusätzlich in das IMM-Filter eingebracht, um der Orts- und Situationsabhängigkeit der Übergangswahrscheinlichkeiten gerecht zu werden. Bild 4.23 zeigt das graphenbasierte Umfeldmodell und die gitterbasierte Geschwindigkeitshistorie über einem rektifizierten Luftbild. Zu sehen ist, dass die Trajektorien der Objekthypothese für Längs-, Quer- und für abbiegenden Verkehr mit den Kanten des graphenbasierten Umfeldmodells übereinstimmen. Daher wird vorgeschlagen, die *Objekthypothesen den Kanten des graphenbasierten Umfeldmodells zuzuordnen* und die an den Kanten verwalteten Informationen für die Adaption der Übergangsmatrix zu nutzen. Für eine Objekthypothese, die sich deutlich vor einer Kreuzung auf einem geraden Fahrstreifen ohne Abzweigung befindet, ist ein Übergang aus dem Geradeaus- in eines der Abbiegemodelle unwahrscheinlich. Hat sich das Objekt jedoch im Kreuzungsbereich auf einem Fahrstreifen eingeordnet, der nur das Linksabbiegen zulässt, so ist ein Übergang in das Modell für das Linksabbiegen wahrscheinlich. Befindet sich das Objekt auf der Kreuzung zum Beispiel auf einem Fahrstreifen, der nur das Abbiegen nach rechts zulässt, so ist ein Übergang in das Modell für das Linksabbiegen unwahrscheinlich. Auf einem geraden Fahrstreifen ohne Abzweigung hinter der Kreuzung ist ein Übergang und der anschließende Verbleib im Geradeausmodell wahrscheinlich. *Die Informationen, welche Abbiegemöglichkeiten ein Fahrstreifen bietet*, sind im graphenbasierten Umfeldmodell enthalten und werden durch die Zuordnung der Objekthypothesen zu den Kanten des graphenbasierten Umfeldmodells individuell für jede Objekthypothese zugänglich. Im graphenbasierten Umfeldmodell werden noch weitere Informationen verwaltet. Dies sind z. B. die zulässige Höchstgeschwindigkeit, die durchschnittlich gefahrene Geschwindigkeit und Daten aus Verkehrszählungen. Letztere geben Auskunft über die Aufteilung des Verkehrsflusses auf die verschiedenen Fahrstreifen.

Bild 4.24 zeigt den schematischen Ablauf des IMM-Filters nach Bar-Shalom u. a. (2001, S. 454) und die in diesem Abschnitt vorgestellte strukturelle Erweiterung zum Active-Interacting-Multi-Model-Filter (AIMM). Der aus der Literatur bekannte Algorithmus des IMM-Filters unterscheidet sich von dem hier vorgestellten neuartigen AIMM-Filter im Update der Modell- und Mischwahrscheinlichkeiten. In diesem Schritt wird die Information des graphenbasierten Umfeldmodells über eine zusätzliche Erweiterung des IMM-Filters genutzt. Die Übergangswahrscheinlichkeiten werden individuell für jede Objekthypothese an die Situation und den Ort angepasst. Steht die Information des graphenbasierten Umfeldmodells nicht zur Verfügung, so wird (wie aus der Literatur bekannt) im Update der Modell- und Mischwahrscheinlichkeiten

scheinlichkeiten die a priori bestimmte Übergangsmatrix genutzt. In diesem Fall entstehen gegenüber dem IMM-Filter keine Nachteile. Stehen jedoch zusätzliche Informationen zur Verfügung, so wird dieses zur Optimierung der Objektverfolgung gewinnbringend genutzt.

Bild 4.25 zeigt die schematische Darstellung einer Kreuzung mit detaillierten Informatio-




Bild 4.23: Darstellung eines graphenbasierten Umfeldmodells (Fahrbahnen in gelb, Radwege in cyan und Lichtsingalanlagen als graue Kreiszyylinder) und der Geschwindigkeitshistorie (grau) über einem rektifizierten Luftbild³. Beispielhafter Zustand der Objekthypothesen mit geschätzter Position, geschätztem Geschwindigkeitsvektor und der geschätzten Ausdehnung als graue Rechtecke abgebildet. Geschätzte Position des Ego Fahrzeuges in blau dargestellt.

nen über die Fahrstreifen. Überdies sind das mit dem maschinellen Wahrnehmungssystem bestückte Ego-Fahrzeug und die Zuordnung der Objekthypothese abgebildet. *Die Zuordnung der Objekthypothese ist mit Unsicherheiten behaftet* ($\sigma_{Matching, x}$ und $\sigma_{Matching, y}$). Bild 4.26 zeigt die schematische Darstellung der Begrifflichkeiten bei der unsicheren Zuordnung der Objekthypothese zu einem Fahrstreifen. Diese verschiedenen Unsicherheitsdomänen werden in Bild 4.27 dargestellt. So ist die Bestimmung von Position und der Lagewinkel des mit dem maschinellen Wahrnehmungssystem ausgestatteten Ego-Fahrzeuges unsicher ($\sigma_{Ego, x}$, $\sigma_{Ego, y}$ und $\sigma_{Ego, \psi}$). Weiterhin ist die Bestimmung der Objekthypothesenposition unsicher (σ_x und

³Kartengrundlage: Orthophotomosaik 1000 der Stadt Wolfsburg, Geschäftsbereich IT - 15-3 GIS, 2008.

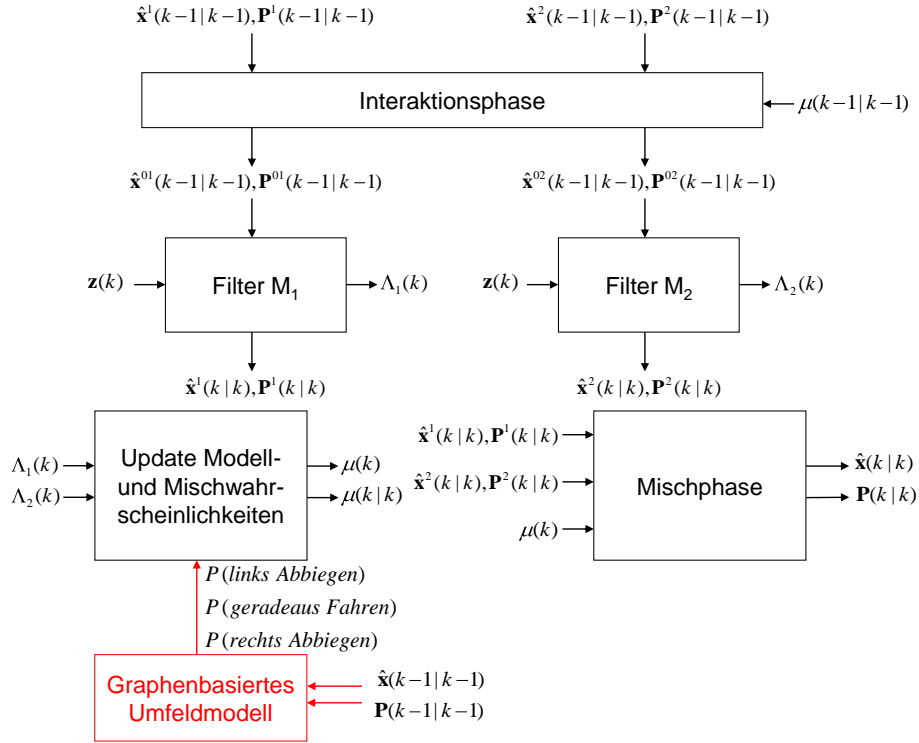


Bild 4.24: Flussdiagramm eines Zyklus des aus der Literatur bekannten Interacting-Multi-Model-Filters nach Bar-Shalom u. a. (2001, S. 454) (in schwarz dargestellt) und der in meiner Arbeit erarbeiteten strukturellen Erweiterung zum Active-Interacting-Multi-Modell-Filter (AIMM). Hierbei wird das klassische IMM-Filter um eine Anpassung der Übergangswahrscheinlichkeiten zur Laufzeit mit Hilfe der zusätzlichen Information eines graphenbasierten Umfeldmodelles erweitert (in rot dargestellt).

σ_y). Die Unsicherheiten der Objekthypothese in globalen Koordinaten berechnen sich hierbei wie folgt:

$$\begin{pmatrix} \sigma_{Matching, x}^2 \\ \sigma_{Matching, y}^2 \end{pmatrix} = \mathbf{R}_{Rot} \cdot \begin{pmatrix} \sigma_x^2 \\ \sigma_y^2 \end{pmatrix} + \begin{pmatrix} \sigma_{Ego, x}^2 \\ \sigma_{Ego, y}^2 \end{pmatrix} + \begin{pmatrix} \left(\left(\sqrt{x^2 + y^2} \right) \cdot \sin(\sigma_{Ego, \psi}) \right)^2 \\ \left(\left(\sqrt{x^2 + y^2} \right) \cdot \cos(\sigma_{Ego, \psi}) \right)^2 \end{pmatrix} \quad (4.54)$$

mit der Rotationsmatrix \mathbf{R}_{Rot} :

$$\mathbf{R}_{Rot} = \begin{pmatrix} \cos \psi & -\sin \psi \\ \sin \psi & \cos \psi \end{pmatrix} \quad (4.55)$$

P_{links} ist die Gesamtwahrscheinlichkeit mit der links abgelenkt wird. $P_{geradeaus}$ und P_{rechts}




Bild 4.25: Schematische Darstellung der mit Unsicherheiten behafteten Zuordnung einer Objekthypothese auf einen Fahrstreifen.

sind die äquivalenten Gesamtwahrscheinlichkeiten für die Geradeausfahrt und das Rechtsabbiegen. Die Gesamtwahrscheinlichkeiten der jeweiligen Verhaltensoptionen setzen sich aus der Summe der bedingten Abbiegewahrscheinlichkeiten über die einzelnen Fahrstreifen zusammen:

$$P_{links} = P_{links|Linksabbiege \text{ Fahrstreifen}} + P_{links|Geradeaus \text{ Fahrstreifen}} + P_{links|Rechtsabbiege \text{ Fahrstreifen}} \quad (4.56)$$

$$P_{geradeaus} = P_{geradeaus|Linksabbiege \text{ Fahrstreifen}} + P_{geradeaus|Geradeaus \text{ Fahrstreifen}} + P_{geradeaus|Rechtsabbiege \text{ Fahrstreifen}} \quad (4.57)$$

$$P_{rechts} = P_{rechts|Linksabbiege \text{ Fahrstreifen}} + P_{rechts|Geradeaus \text{ Fahrstreifen}} + P_{rechts|Rechtsabbiege \text{ Fahrstreifen}} \quad (4.58)$$

Die bedingten Abbiegewahrscheinlichkeiten je Fahrstreifen sind hierbei *Verkehrserhebungen* entnommen worden. Diese Daten sind auf drei verschiedene Tageszeiten aufgeschlüsselt: Morgens, Mittags und Abends. Für die Berechnung der Verhaltenshypothese der Objekthypothesen wird das Integral zwischen den Fahrstreifenbegrenzungen über die Unsicherheitsverteilung (vgl. Bild 4.26) berechnet und daraus eine *Fahrstreifenzuordnungswahrscheinlichkeit* gebildet. Hierbei wird aus einer Worst-Case-Abschätzung das Maximum der Unsicherheit in

x und y bestimmt:

$$P_{\text{Linksabbiege Fahrstreifen}} = \int_{\text{li. Begr. li.Fahrs.}}^{\text{re. Begr. li.Fahrs.}} \Phi_{\mu, \max(\sigma_{\text{Matching}, x}, \sigma_{\text{Matching}, y})} \quad (4.59)$$

$$P_{\text{Geradeaus Fahrstreifen}} = \int_{\text{li. Begr. ge.Fahrs.}}^{\text{re. Begr. ge.Fahrs.}} \Phi_{\mu, \max(\sigma_{\text{Matching}, x}, \sigma_{\text{Matching}, y})} \quad (4.60)$$

$$P_{\text{Rechtsabbiege Fahrstreifen}} = \int_{\text{li. Begr. re.Fahrs.}}^{\text{re. Begr. re.Fahrs.}} \Phi_{\mu, \max(\sigma_{\text{Matching}, x}, \sigma_{\text{Matching}, y})} \quad (4.61)$$

Die Fahrstreifenzuordnungswahrscheinlichkeiten (z. B. $P_{\text{Linksabbiege Fahrstreifen}}$) und die bedingten Abbiegewahrscheinlichkeiten (z. B. $P_{\text{links}|\text{Linksabbiege Fahrstreifen}}$) werden mit Hilfe des Gesetzes der totalen Wahrscheinlichkeit zur Generierung der Verhaltenshypothesen genutzt:

$$P(A) = \sum_{j=1}^n P(B_j) \cdot P(A|B_j) \quad (4.62)$$

$$\begin{aligned} P_{\text{links Abbiegen}} &= P_{\text{Linksabbiege Fahrstreifen}} \cdot P_{\text{links}|\text{Linksabbiege Fahrstreifen}} \\ &+ P_{\text{Geradeaus Fahrstreifen}} \cdot P_{\text{links}|\text{Geradeaus Fahrstreifen}} \\ &+ P_{\text{Rechtsabbiege Fahrstreifen}} \cdot P_{\text{links}|\text{Rechtsabbiege Fahrstreifen}} \end{aligned} \quad (4.63)$$

$$\begin{aligned} P_{\text{geradeaus Fahren}} &= P_{\text{Linksabbiege Fahrstreifen}} \cdot P_{\text{geradeaus}|\text{Linksabbiege Fahrstreifen}} \\ &+ P_{\text{Geradeaus Fahrstreifen}} \cdot P_{\text{geradeaus}|\text{Geradeaus Fahrstreifen}} \\ &+ P_{\text{Rechtsabbiege Fahrstreifen}} \cdot P_{\text{geradeaus}|\text{Rechtsabbiege Fahrstreifen}} \end{aligned} \quad (4.64)$$

$$\begin{aligned} P_{\text{rechts Abbiegen}} &= P_{\text{Linksabbiege Fahrstreifen}} \cdot P_{\text{rechts}|\text{Linksabbiege Fahrstreifen}} \\ &+ P_{\text{Geradeaus Fahrstreifen}} \cdot P_{\text{rechts}|\text{Geradeaus Fahrstreifen}} \\ &+ P_{\text{Rechtsabbiege Fahrstreifen}} \cdot P_{\text{rechts}|\text{Rechtsabbiege Fahrstreifen}} \end{aligned} \quad (4.65)$$

Die Übergangsmatrix ergibt sich daraus wie folgt:

$$\mathbf{P}^t = \begin{pmatrix} \frac{P_{\text{geradeaus Fahren}}}{\sum_{i=1}^3 P_i} & \frac{P_{\text{links Abbiegen}}}{\sum_{i=1}^3 P_i} & \frac{P_{\text{rechts Abbiegen}}}{\sum_{i=1}^3 P_i} \\ \frac{P_{\text{geradeaus Fahren}}}{\sum_{i=1}^3 P_i} & \frac{P_{\text{links Abbiegen}}}{\sum_{i=1}^3 P_i} & \frac{P_{\text{rechts Abbiegen}}}{\sum_{i=1}^3 P_i} \\ \frac{P_{\text{geradeaus Fahren}}}{\sum_{i=1}^3 P_i} & \frac{P_{\text{links Abbiegen}}}{\sum_{i=1}^3 P_i} & \frac{P_{\text{rechts Abbiegen}}}{\sum_{i=1}^3 P_i} \end{pmatrix} \quad (4.66)$$

Hierbei gilt für die Zuordnung der einzelnen Modelle:

- Modell 1: geradeaus mit konstanter Geschwindigkeit
- Modell 2: gegen den Uhrzeigersinn auf einer Kreisbahn mit konstanter Geschwindigkeit
- Modell 3: im Uhrzeigersinn auf einer Kreisbahn mit konstanter Geschwindigkeit




Bild 4.26: Darstellung der Begrifflichkeiten bei der unsicheren Zuordnung der Objekthypothese zu einem Fahrstreifen.

Die aktive Steuerung der Übergangsmatrix wird im Folgenden exemplarisch anhand eines Beispiels erläutert. Hierbei wird symbolisch zwischen vier Bereichen unterschieden (grün, blau, rot, orange, vgl. Bild 4.28). Die Übergänge zwischen den Bereichen sind fließend und ergeben sich aus den Fahrstreifenzuordnungswahrscheinlichkeiten der einzelnen Objekthypothesen. Der grüne und der orangefarbige Bereich sind dadurch charakterisiert, dass die Objekthypothesen hier nur die Möglichkeit haben, geradeaus zu fahren (vgl. Verhaltenswahrscheinlichkeiten in Tabelle 4.6). Der orangene Bereich beginnt 5m nach der Kreuzung. Der blaue und der rote Bereich sind nur zur Veranschaulichung getrennt, die Übergänge zwischen den Bereichen sind fließend. Für beide Bereiche werden die *Abbiegewahrscheinlichkeiten* anhand von realen Verkehrsdatenerhebungen bestimmt (vgl. Tabellen 4.6 und 4.8). Die Unterscheidung zwischen dem blauen und dem roten Bereich ergibt sich aus der unterschiedlichen räumlichen Distanz der verschiedenen Fahrstreifen. Dies resultiert im Falle einer großen räumlichen Distanz in einer eindeutigen Fahrstreifenzuordnungswahrscheinlichkeit (roter Bereich) und im Falle einer geringeren Distanz in einer weniger aussagekräftigen Fahrstreifenzuordnungswahrscheinlichkeit. Die Funktionsweise des Algorithmus wird anhand zweier Szenarien erläutert (Trajektorie 1 und Trajektorie 2, vgl. Bild 4.28). Die Szenarien unterscheiden sich bezüglich der, aus der Fahrstreifenzuordnung resultierenden, Verhaltensoptionen. Trajektorie 1 führt über einen Fahrstreifen, der zwei Optionen zulässt: Die Objekthypothese kann Geradeausfahren oder Rechtsabbiegen. Wie die Objekthypothese sich




Bild 4.27: Schematische Darstellung der verschiedenen Unsicherheitsdomänen bei der Objekthypothesenverfolgung in einem globalen Koordinatensystem.

verhalten wird, ist allein aus der Information der Fahrstreifenzuordnung nicht zu bestimmen. Trajektorie 2 führt über einen Fahrstreifen, der nur eine Option zulässt: Die Objekthypothese kann auf diesem Fahrstreifen (unter der Voraussetzung, dass die Objekthypothese sich konform zu den geltenden Verkehrsregeln verhält) nur Linksabbiegen.

Tabelle 4.7 und 4.9 zeigen die Entwicklung der Übergangsmatrix über die vier Bereiche. Vor und nach der Kreuzung (grüner und orangener Bereich) ist primär (mit einer Wahrscheinlichkeit von 98 %) mit einem Wechsel in das Geradeausmodell oder einem Verbleib im Geradeausmodell zu rechnen. Dies resultiert aus den nicht vorhandenen Abbiegemöglichkeiten in diesen Bereichen. Kurz vor der Kreuzung (blauer Bereich, Trajektorie 1) ist auf Grund der Informationen der Verkehrsdatenerhebung ein Wechsel in das Modell für das Rechtsabbiegen mit 81,9 % dominant (vgl. Tabelle 4.6). Die Fahrstreifenzuordnungshypothese allein führt in diesem Bereich zu keiner eindeutigen Evidenz zwischen den Möglichkeiten des Geradeausfahrens und des Rechtsabbiegens. Im Kreuzungsbereich erhöht sich die Wahrscheinlichkeit eines Wechsels in das Modell für das rechts Abbiegen auf 99,1 %. In diesem Bereich liefert die Fahrstreifenzuordnungshypothese eine zusätzliche eindeutige Evidenz bezüglich des Modelles für das Rechtsabbiegen. Für Trajektorie 2 ist im blauen Bereich (vgl. Tabelle 4.8) ein Wechsel in das Modell für das Linksabbiegen mit 78,6 % dominant. Die Fahr-




Bild 4.28: Darstellung eines graphenbasierten Umfeldmodelles über einem rektifizierten Luftbild und Verdeutlichung der vier verwendeten Bereiche (vor- (grün), kurz vor- (blau), auf- (rot) und nach (orange) der Kreuzung) ⁴.

streifenzuordnungshypothese führt in diesem Bereich zu einer eindeutigen Evidenz bezüglich des Modelles für das Linksabbiegen. Im Kreuzungsbereich erhöht sich die Wahrscheinlichkeit eines Wechsels in das Modell für das Linksabbiegen auf 89,7 %.

4.4.3 Diskussion

In diesem Abschnitt wird ein Verfahren zur allgemeingültigen Bestimmung der Übergangswahrscheinlichkeiten zur Laufzeit individuell für jede Objekthypothese vorgestellt. Der vorgestellte Ansatz benötigt in der Position eine fahrstreifengenaue globale Ortung. Weiterhin ist ein fahrstreifengenaues graphenbasiertes Umfeldmodell notwendig.

Werden Dynamikmodelle durch die Wahl der Übergangsmatrix ausgeschlossen (betreffende Übergangswahrscheinlichkeiten sind 0), so findet indirekt eine Beeinflussung der Modell-Sets statt. Das Verfahren beinhaltet damit indirekt auch die von Zhang u. a. (2008) vorgeschlagene Beeinflussung der Modell-Sets, ermöglicht aber weitergehend die individuelle Beeinflus-

⁴Kartengrundlage: Orthophotomosaik 1000 der Stadt Wolfsburg, Geschäftsbereich IT - 15-3 GIS, 2008.

Bedingte Verhaltenswahrscheinlichkeiten		
$P_{links linksabbiege \text{ Fahrstreifen}}$	=	0,00 %
$P_{links geradeaus \text{ Fahrstreifen}}$	=	1,00 %
$P_{links rechtsabbiege \text{ Fahrstreifen}}$	=	0,00 %
$P_{geradeaus linksabbiege \text{ Fahrstreifen}}$	=	0,00 %
$P_{geradeaus geradeaus \text{ Fahrstreifen}}$	=	98,00 %
$P_{geradeaus rechtsabbiege \text{ Fahrstreifen}}$	=	0,00 %
$P_{rechts linksabbiege \text{ Fahrstreifen}}$	=	0,00 %
$P_{rechts geradeaus \text{ Fahrstreifen}}$	=	1,00 %
$P_{rechts rechtsabbiege \text{ Fahrstreifen}}$	=	0,00 %

Tabelle 4.5: Modellierung der Verhaltenswahrscheinlichkeit für den Bereich vor (grün) und nach (orange) einer Kreuzung (vgl. Bild 4.28).

Bedingte Verhaltenswahrscheinlichkeiten		
$P_{links linksabbiege \text{ Fahrstreifen}}$	=	30,50 %
$P_{links geradeaus \text{ Fahrstreifen}}$	=	0,00 %
$P_{links rechtsabbiege \text{ Fahrstreifen}}$	=	0,00 %
$P_{geradeaus linksabbiege \text{ Fahrstreifen}}$	=	0,00 %
$P_{geradeaus geradeaus \text{ Fahrstreifen}}$	=	11,01 %
$P_{geradeaus rechtsabbiege \text{ Fahrstreifen}}$	=	0,00 %
$P_{rechts linksabbiege \text{ Fahrstreifen}}$	=	0,00 %
$P_{rechts geradeaus \text{ Fahrstreifen}}$	=	0,00 %
$P_{rechts rechtsabbiege \text{ Fahrstreifen}}$	=	58,49 %

Tabelle 4.6: Datengrundlage aus Verkehrszählungen für Trajektorie 1 aus Bild 4.28 für den blauen und den roten Bereich.

sung der Übergangswahrscheinlichkeiten für jede Objekthypothese. Treten Unsicherheiten in der A-Priori-Information auf, z. B. durch *Fehler oder Unsicherheiten im Kartenmaterial*, so führen diese zu einer unsicheren Zuordnung der Objekthypothesen zu den Kanten des graphenbasierten Umfeldmodelles. In einem gewissen Maße (Fehler < Fahrstreifenbreite) werden diese Unsicherheiten somit in dem vorgestellten Ansatz berücksichtigt. Treten größere Kartenfehler auf (Kreuzungsast fehlt komplett, da die Karte z. B. veraltet ist), so wird die Objekthypothese nicht zugeordnet. Das Filter verhält sich wie das klassische IMM-Filter und wird von den Messdaten des eingesetzten Sensors dominiert. Das beschriebene AIMM-Filter benötigt daher fahrstreifengenaue und aktuelle Navigationskartendaten möglichst mit aktuellen Verkehrszählungen.

Das vorgestellte Verfahren hat den Vorteil, dass es eine *modulare Erweiterung zum be-*

Bereich	Beispielhafte Fahrstreifenzuordnungswahrscheinlichkeiten	Resultierende Übergangswahrscheinlichkeiten
Grün	$P_{\text{linksabbiege Fahrstreifen}} = 6 \%$ $P_{\text{geradeaus Fahrstreifen}} = 94 \%$ $P_{\text{rechtsabbiege Fahrstreifen}} = 94 \%$	$\mathbf{P}^t = \begin{pmatrix} 0.98 & 0.01 & 0.01 \\ 0.98 & 0.01 & 0.01 \\ 0.98 & 0.01 & 0.01 \end{pmatrix}$
Blau	$P_{\text{linksabbiege Fahrstreifen}} = 6 \%$ $P_{\text{geradeaus Fahrstreifen}} = 94 \%$ $P_{\text{rechtsabbiege Fahrstreifen}} = 94 \%$	$\mathbf{P}^t = \begin{pmatrix} 0.154 & 0.027 & 0.819 \\ 0.154 & 0.027 & 0.819 \\ 0.154 & 0.027 & 0.819 \end{pmatrix}$
Rot	$P_{\text{linksabbiege Fahrstreifen}} = 1 \%$ $P_{\text{geradeaus Fahrstreifen}} = 2 \%$ $P_{\text{rechtsabbiege Fahrstreifen}} = 97 \%$	$\mathbf{P}^t = \begin{pmatrix} 0.004 & 0.005 & 0.991 \\ 0.004 & 0.005 & 0.991 \\ 0.004 & 0.005 & 0.991 \end{pmatrix}$
Orange	$P_{\text{linksabbiege Fahrstreifen}} = 0 \%$ $P_{\text{geradeaus Fahrstreifen}} = 100 \%$ $P_{\text{rechtsabbiege Fahrstreifen}} = 0 \%$	$\mathbf{P}^t = \begin{pmatrix} 0.98 & 0.01 & 0.01 \\ 0.98 & 0.01 & 0.01 \\ 0.98 & 0.01 & 0.01 \end{pmatrix}$

Tabelle 4.7: Beispielhafte Vorstellung der Adaption der Übergangswahrscheinlichkeiten anhand von Trajektorie 1 aus Bild 4.28.

kannten IMM-Filter darstellt. Die Erweiterung ist sehr effizient und benötigt nur einen geringen Rechenaufwand. Zusätzlich hat das vorgestellte Active-Interacting-Multi-Model-Filter (AIMM) den Vorteil, dass es sich im Vergleich zu Bayes'schen Netzen deterministisch verhält und nicht durch unsicheres Expertenwissen oder unsichere Lerndaten angelernet wird. Der Ansatz ist um zukünftige Informationsbasen (wie z. B. Extended Floating Car Data) erweiterbar. Teile dieses Abschnitts sind in Dyckmanns u. a. (2011a) und Dyckmanns u. a. (2011b) veröffentlicht worden.

Grenzen: Der vorgestellte Ansatz setzt unter anderem voraus, dass sich die Verkehrsteilnehmer an die geltenden Verkehrsregeln halten. Das heißt beispielsweise, befindet sich ein Verkehrsteilnehmer auf einem expliziten Fahrstreifen für das Linksabbiegen, so wird angenommen, dass der Verkehrsteilnehmer in diesem Fall auch tatsächlich links abbiegen wird. Diese Randbedingung ist im realen Verkehrsgeschehen zwar in der Regel erfüllt, aber bei ei-

Bedingte Verhaltenswahrscheinlichkeiten		
$P_{links linksabbiege \text{ Fahrstreifen}}$	=	13,76 %
$P_{links geradeaus \text{ Fahrstreifen}}$	=	0,00 %
$P_{links rechtsabbiege \text{ Fahrstreifen}}$	=	0,00 %
$P_{geradeaus linksabbiege \text{ Fahrstreifen}}$	=	0,00 %
$P_{geradeaus geradeaus \text{ Fahrstreifen}}$	=	66,30 %
$P_{geradeaus rechtsabbiege \text{ Fahrstreifen}}$	=	0,00 %
$P_{rechts linksabbiege \text{ Fahrstreifen}}$	=	0,00 %
$P_{rechts geradeaus \text{ Fahrstreifen}}$	=	0,00 %
$P_{rechts rechtsabbiege \text{ Fahrstreifen}}$	=	19,94 %

Tabelle 4.8: Datengrundlage aus Verkehrszählungen für Trajektorie 2 aus Bild 4.28 für den blauen und den roten Bereich.

ner Verletzung dieser Annahmen sind zwei Fälle möglich: Die Objekthypothese kann keiner Kante zugeordnet werden, der Algorithmus verhält sich nun wie das klassische IMM-Filter. Ein Nachteil entsteht nicht. Problematischer ist der Fall, in dem eine Objekthypothese bei einer Ausholbewegung (z. B. bei einem Wendemanöver) einer falschen Kante zugeordnet wird. Dieser Fall wird jedoch in der praktischen Validierung der Algorithmen in Abschnitt 5.3.2 betrachtet.

4.5 Fazit

Im vorherigen Kapitel wird eine Multiobjektverfolgung mit einem einzelnen seriennahen Laserscanner in urbanen Kreuzungsbereichen realisiert. Hierbei ermöglichen hybride Umfeldmodelle, durch eine Reduktion der Objekthypothesen die Nutzung komplexerer Multi-Modell Ansätze. Die Ansätze verfügen im Vergleich zu den unimodalen Filtern über zwei zusätzliche Design-Parameter, welche a-priori nicht optimal zu bestimmen sind. Daher wird im Kontext hybrider Umfeldmodelle *ein neuartiger Ansatz zur Fusion objekt- und graphenbasierter Darstellungsformen präsentiert*. Dieser ermöglicht eine Adaption der zusätzlichen Design-Parameter zur Laufzeit individuell für jede Objekthypothese. Hierfür wird jede Objekthypothese dem graphenbasierten Umfeldmodell zugeordnet und die so erhaltenen zusätzlichen Informationen über den Fahrstreifenverlauf genutzt.

Zudem wird ein Objektmodell vorgestellt, das invariant gegenüber Konturabweichungen ist und *sowohl Längs- als auch Querverkehr ohne eine anfällige Fallunterscheidung verfolgt*. Außerdem stellt das vorgestellte Objektmodell zu jeder Zeit eine Beobachtbarkeit aller Zustände sicher. Im diskutierten Ansatz werden die Dynamikmodelle Rechtsabbiegen, Linksab-

Bereich	Beispielhafte Fahrstreifenzuordnungswahrscheinlichkeiten	Resultierende Übergangswahrscheinlichkeiten
Grün	$P_{\text{linksabbiege Fahrstreifen}} = 94 \%$ $P_{\text{geradeaus Fahrstreifen}} = 5 \%$ $P_{\text{rechtsabbiege Fahrstreifen}} = 1 \%$	$\mathbf{P}^t = \begin{pmatrix} 0.98 & 0.01 & 0.01 \\ 0.98 & 0.01 & 0.01 \\ 0.98 & 0.01 & 0.01 \end{pmatrix}$
Blau	$P_{\text{linksabbiege Fahrstreifen}} = 94 \%$ $P_{\text{geradeaus Fahrstreifen}} = 5 \%$ $P_{\text{rechtsabbiege Fahrstreifen}} = 1 \%$	$\mathbf{P}^t = \begin{pmatrix} 0.202 & 0.786 & 0.012 \\ 0.202 & 0.786 & 0.012 \\ 0.202 & 0.786 & 0.012 \end{pmatrix}$
Rot	$P_{\text{linksabbiege Fahrstreifen}} = 97 \%$ $P_{\text{geradeaus Fahrstreifen}} = 2 \%$ $P_{\text{rechtsabbiege Fahrstreifen}} = 1 \%$	$\mathbf{P}^t = \begin{pmatrix} 0.089 & 0.897 & 0.013 \\ 0.089 & 0.897 & 0.013 \\ 0.089 & 0.897 & 0.013 \end{pmatrix}$
Orange	$P_{\text{linksabbiege Fahrstreifen}} = 0 \%$ $P_{\text{geradeaus Fahrstreifen}} = 100 \%$ $P_{\text{rechtsabbiege Fahrstreifen}} = 0 \%$	$\mathbf{P}^t = \begin{pmatrix} 0.98 & 0.01 & 0.01 \\ 0.98 & 0.01 & 0.01 \\ 0.98 & 0.01 & 0.01 \end{pmatrix}$

Tabelle 4.9: Beispielhafte Vorstellung der Adaption der Übergangswahrscheinlichkeiten anhand von Trajektorie 2 aus Bild 4.28.

biegen und Geradeausfahren zur Minimierung der Zustandsunsicherheit bei querdynamischen Manövern eingesetzt. Eine nachträgliche Konturschätzung ermöglicht es, detaillierte Konturinformationen effizient für relevante Objekthypothesen zu berechnen. Dies minimiert die Rechenkomplexität. Zusätzlich haben Fehler aus der Konturschätzung keine Rückwirkungen auf den eigentlichen Filterprozess.

Um auch für einen rein distanzmessenden Sensor eine schnelle Initialisierung der Geschwindigkeit zu ermöglichen, wird ein neuartiges Verfahren zur Fusion objekt- und gitterbasierter Darstellungsformen präsentiert. Dieses ermöglicht die Minimierung der *Objektdetektionslatenz* auf günstigenfalls 2 Messzyklen (120ms). Hierfür werden die Geschwindigkeitsinformationen bisher verfolgter Objekthypothesen in einer gitterbasierten Darstellungsform gespeichert. Wird eine Objekthypothese neu initialisiert, so wird ein ähnliches Verhalten wie bei den bisher detektierten Objekthypothesen angenommen. Die an der betreffenden Stelle ge-

speicherte Geschwindigkeitsinformation wird für die neu zu initialisierende Objekthypothese übernommen. Wird diese Objekthypothese durch die ersten beiden Entfernungsmessungen bestätigt, so wird die Objekthypothese ausgegeben.

Ziel dieser Arbeit	Lösungsansatz	Abs.
Verwendung eines einzelnen seriennahen Laserscanners	Realisierung mittels eines Hella IDIS 2.0	4.2
Low-Level-Fusion objekt- und gitterbasierter Darstellungen	Verbesserte Initialisierung mittels gitterbasierter Geschwindigkeits-historie	4.3
situationsabhängige Anpassung der Übergangswahrscheinlichkeiten zur Laufzeit	Adaption mit Hilfe von Verhaltenswahrscheinlichkeiten aus graphenbasiertem Umfeldmodell	4.4
Low-Level-Fusion objekt- und graphenbasierter Darstellungen	Verringerte Zustandsunsicherheit durch Zuordnung der Objekthypothesen auf graphenbasiertes Umfeldmodell zur Laufzeit	4.4

Tabelle 4.10: Tabellarische Übersicht der Ziele dieser Arbeit (vgl. Tabelle 2.2) und der technischen Realisierung.

5 Experimentelle Validierung des technischen Lösungsansatzes

Die Ergebnisse der experimentellen Validierung der Algorithmen werden im Folgenden vorgestellt und diskutiert (vgl. Bild 5.1).




Bild 5.1: Grafische Darstellung der Gliederung von Kapitel 5

5.1 Versuchsaufbau und -technik

Für die experimentelle Validierung der Algorithmen werden zwei, bezüglich der im Kontext dieser Arbeit relevanten Hardware, baugleiche Volkswagen Passat CC eingesetzt (vgl. Bild 5.3). Beide Fahrzeuge sind mit einem Hella IDIS 2.0 Laserscanner für die maschinelle Umfeldwahrnehmung ausgestattet. Dieser ist in das Lüftungsgitter der Frontschürze integriert (vgl. Bild 5.4). Zur Erzeugung der Referenzdaten sind beide Versuchsträger mit dem Koppelnavigationssystem RT3002 der Firma Oxford Technical Solutions Limited (oxts) ausgestattet. Die Referenzdaten sind jeweils auf den, der Front des Ego-Fahrzeuges nächst gelegenen, Referenzpunkt bezogen. Die vier Referenzpunkte werden in Abbildung 5.2 dargestellt. Im Falle von Abbiegeszenarien folgt der Referenzpunkt etwaigen Perspektivwechseln. Die Berechnung der Algorithmen erfolgt im Fahrzeug in Echtzeit auf Standard-PC-Komponenten. Auf Grund der Möglichkeit, Szenarien unter vergleichbaren Bedingungen zu reproduzieren, sind die folgenden Experimente im Prüfgelände durchgeführt worden. Außerdem hat das Prüfgelände den Vorteil, dass hier kritische und gefährliche Szenarien dargestellt werden können, ohne Dritte zu gefährden. Des Weiteren werden die Koppelnavigationssysteme unter freiem Himmel auf dem Prüfgelände gemäß ihrer Spezifikation betrieben (vgl. Abschnitt 3.1), so dass

die Referenzdaten als belastbar angenommen werden können.




Bild 5.2: Definition der vier verwendeten Referenzpunkte, relevant ist jeweils der, der Front des Ego-Fahrzeugs nächst gelegene Referenzpunkt.



Bild 5.3: Darstellung des Versuchsträgers und des Sensorsetups.



Bild 5.4: Darstellung des Laserscanners Hella IDIS 2.0 am Versuchsträger.

Die Szenarien bilden einen repräsentativen Querschnitt über die in Kreuzungsbereichen auftretenden Verkehrssituationen. Die Messdaten sind zu unterschiedlichen Zeitpunkten aufgenommen worden, um die Reliabilität der Daten sicher zu stellen. Die verwendeten Szenarien lassen sich auf folgenden Komponenten zusammensetzen:

- Querverkehr von rechts biegt rechts, bzw. links ab oder fährt gradeaus
- Querverkehr von links biegt rechts, bzw. links ab oder fährt gradeaus
- Längsverkehr biegt rechts bzw. links ab, fährt gradeaus oder wendet mittels U-Turn.

5.2 Evaluierung des Objekttracking-Systemes

In diesem Abschnitt wird die Leistungsfähigkeit des vorgestellten Tracking-Algorithmus anhand realer Messdaten aufgezeigt.




Bild 5.5: Grafische Darstellung der Gliederung von Kapitel 5.2

5.2.1 Positions- und Geschwindigkeitsschätzung

Die Güte der Positions- und Geschwindigkeitsschätzung im Vergleich zu Referenzdaten und die Unsicherheit der Schätzung werden in diesem Abschnitt evaluiert. Hierfür wird exemplarisch ein *Szenario mit Querverkehr von links* gewählt. Bild 5.6 zeigt die Topologie der Kreuzung in Form des graphenbasierten Umfeldmodelles. Das mit dem maschinellen Wahrnehmungssystem ausgestattete Fahrzeug ist mit dem Sichtbereich der Sensoren visualisiert. Die Objekthypothese mit dem zugehörigen Geschwindigkeitsvektor ist orange dargestellt. Außerdem ist der Verlauf der Geschwindigkeitshistorie (orange) zu sehen. Die Auswertung der Messdaten ergibt folgende Auffälligkeiten:

Konturpunktsprünge: Der Konturpunkt ist zunächst in der Mitte der Front, wechselt dann auf die Mitte der rechten Seite und abschließend auf die Mitte des Hecks. Die Schätzung folgt den Sprüngen nur träge, dies wirkt sich bei 1s und bei 4,3s negativ auf die Schätzung der lateralen Position der Objekthypothese gegenüber den Referenzdaten (Bild 5.7) aus.

Unsicherheiten auf Grund eines ungünstigen Betrachtungswinkels treten auf, wenn das Objekt z. B. unter einem sehr spitzen Winkel detektiert wird. Die Schätzung der longitudinalen Position der Objekthypothese gegenüber den Referenzdaten weist aus diesem Grund im Bereich von 0s bis 4s auffällige Abweichungen auf (Bild 5.8). Die Unsicherheit, mit der die Schätzung der Position erfolgt, wird in Bild 5.9 gezeigt. Die Unsicherheit der longitudinalen Positionsschätzung ist im Zentrum auf Grund des günstigen Betrachtungswinkels am geringsten und steigt dann zu den Randbereichen des Sensorsichtbereichs merklich an.

Entfernungsabhängige Unsicherheit resultierend aus der Strahlgeometrie: Die




Bild 5.6: Darstellung des Szenarios: Das mit dem maschinellen Wahrnehmungssystem ausgestattete Fahrzeug bewegt sich mit konstanter Geschwindigkeit (ca. $30 \frac{km}{h}$) auf dem Linksabbiege-Fahrbahnstreifen auf die Kreuzung zu. Die Objekthypothese bewegt sich von links mit ca. $30 \frac{km}{h}$ auf die Kreuzung zu und biegt im weiteren Verlauf im Kreuzungsbereich links ab.

laterale Positionsschätzung ist auf Grund der Strahlgeometrie (Strahlaufweitung 1°) von 3s bis 9s mit einer größeren Unsicherheit behaftet als die longitudinale Positionsschätzung. Von 0s bis 3s ist das Ergebnis der longitudinalen Positionsschätzung mit einer größeren Unsicherheit behaftet (Bild 5.9). Bild 5.10 zeigt die laterale Geschwindigkeitsschätzung der Objekthypothese. Signifikante Abweichungen sind vor allem im Bereich ab 7s zu bemerken. Die Objekthypothese entfernt sich in diesem Zeitraum immer weiter vom Sensor. Die Unsicherheiten, die aus der Strahlaufweitung resultieren, fallen somit stärker ins Gewicht. Bild 5.11 zeigt das Ergebnis der longitudinalen Geschwindigkeitsschätzung der Objekthypothese im Vergleich zu den Referenzdaten. Auf Grund des ungünstigen Betrachtungswinkels und der Strahlaufweitung weist diese von 0s bis 4s nennenswerte Abweichungen auf, jedoch bessert sich der Aspektwinkel und damit auch die Güte der Geschwindigkeitsschätzung nach dem Abbiegemanöver (ab 5s). Die Unsicherheiten der Geschwindigkeitsschätzung werden in Bild 5.12 dargestellt. Auf Grund des ungünstigen Betrachtungswinkels ist diese zu Beginn am höchsten, sinkt dann aber im Zentrum merklich ab.

Es wird festgestellt, dass das vorgestellte Verfahren in der Lage ist, Objekthypothesen im Kreuzungsbereich zu verfolgen. Die Unsicherheit von Positions- und Geschwindigkeitsschätzung hängt im Wesentlichen von der Entfernung der Objekthypothese zum Sensor und dem Aspektwinkel, unter dem die Objekthypothese beobachtet wird, ab.




Bild 5.7: Darstellung der lateralen Positionsschätzung der Objekthypothese (blau) im Vergleich zu den Referenzdaten (rot).




Bild 5.8: Darstellung der longitudinalen Positionsschätzung der Objekthypothese (blau) im Vergleich zu den Referenzdaten (rot).




Bild 5.9: Darstellung der Unsicherheit der Positionsschätzung der Objekthypothese (Lateral - blau, Longitudinal - schwarz).




Bild 5.10: Darstellung der lateralen Geschwindigkeitsschätzung der Objekthypothese (blau) im Vergleich zu den Referenzdaten (rot).




Bild 5.11: Darstellung der longitudinalen Geschwindigkeitsschätzung der Objekthypothese (blau) im Vergleich zu den Referenzdaten (rot).




Bild 5.12: Darstellung der Unsicherheit bei der Geschwindigkeitsschätzung (Lateral - blau, Longitudinal - schwarz).

5.2.2 Nachträgliche Konturschätzung

Wie in Abschnitt 5.2.1 gezeigt wird, folgen die Positionsschätzungen den Referenzdaten im Fall von Sprüngen des Konturpunktes nur träge. Um in dieser Hinsicht Verbesserung zu erzielen, wird in Abschnitt 4.2.8 die nachträgliche Konturschätzung vorgestellt und im Folgenden evaluiert. Dem mit dem maschinellen Wahrnehmungssystem ausgestatteten Fahrzeug *kommt im Kreuzungsbereich ein Fahrzeug entgegen, welches rechts abbiegt*.

Konturpunktsprünge: Bild 5.14 zeigt die Ergebnisse der lateralen Positionsschätzung der Objekthypothese einmal mit und einmal ohne nachträgliche Konturschätzung. Auffällig sind die Sprünge der Konturpunkte in den Referenzdaten (10,5s und 12,4s). Die Position ohne Konturschätzungen folgt diesen Änderungen träge und ohne Sprünge (grün gestrichelt). Die durch die nachträgliche Konturschätzung erzeugte Position weist Sprünge bei 10s (etwas zu früh im Vergleich zur Referenz) und 12,7s (etwas zu spät im Vergleich zur Referenz) auf. Dies führt im Bereich von 8,5s bis 10s und im Bereich von 13s bis 14s zu einer erhöhten Richtigkeit der Positionsschätzung. Im Bereich von 9s bis 10s ist die Variante mit Konturschätzung bezüglich der longitudinalen Positionsschätzung (vgl. Bild 5.15) minimal überlegen, im restlichen Betrachtungszeitraum sind keine erheblichen Unterschiede erkennbar. Bild 5.16 und 5.17 zeigen, dass die nachträgliche Konturschätzung keinen Einfluss auf die Geschwindigkeitsschätzung nimmt. Die Schätzung des Lagewinkels der Objekthypothese




Bild 5.13: Darstellung des Szenarios: Die Objekthypothese bewegt sich von vorne mit ca. $30 \frac{km}{h}$ auf dem Rechtsabbiege-Fahrsstreifen auf die Kreuzung zu und biegt im weiteren Verlauf im Kreuzungsbereich rechts ab.

im Vergleich zu den Referenzdaten zeigt Bild 5.18. Während die Objekthypothese geradeaus fährt (0s bis 8s) sind keine bedeutsame Abweichungen erkennbar. Mit Beginn des Abbiegemanövers (ab 8s) sind größere Abweichungen zu erkennen. Der Vergleich der normalisierten Fehlerquadrate für die laterale und die longitudinale Positionsschätzung in Bild 5.20 zeigt, dass die nachträgliche Konturschätzung im Bereich von 8,5s bis 10s einen Vorteil bietet. Jedoch werden erhöhte Werte von 10s bis 14s mit keiner der beiden Varianten verhindert. Werden die Varianz, der Mittelwert und der Maximalwert der Wurzel des quadratischen Fehlers für die Differenz zwischen Zustandsschätzung der Objekthypothese und den Referenzdaten mit und ohne nachträglicher Konturschätzung verglichen (vgl. Tabelle 5.1), so ist die nachträgliche Konturschätzung leicht überlegen. Lediglich der maximale laterale Fehler ist ohne nachträgliche Konturschätzung minimal geringer. Wesentliche Abweichungen zwischen beiden Verfahren werden nicht festgestellt.

Unsicherheiten auf Grund eines ungünstigen Betrachtungswinkels: Das Ergebnis der Schätzung der Parameter Länge und Breite im Vergleich zu den Referenzdaten zeigt Bild 5.19. Im Bereich von 0s bis 8,2s und ab 13s ist die Länge nicht beobachtbar und wird daher mit einem vordefinierten Wert angenommen. Zwischen 8,2s und 13s ist die Breite nicht beobachtbar, daher erfolgt in diesem Zeitraum eine feste Annahme. Im übrigen Zeitraum ist die Schätzung der Breite aufgrund des günstigen Aspektwinkels möglich. Die Schätzung der Länge weist während des Abbiegemanövers Abweichungen auf. Es wird festgestellt, dass die nachträgliche Konturschätzung zu keiner deutlichen Verbesserung ohnehin geschätzter

	ohne Kontur	mit Kontur
RMSE y	0,7977 m	0,7432 m
RMSE x	0,3446 m	0,3041 m
var(RSE) y	0,5546 m ²	0,5356 m ²
var(RSE) x	0,1447 m ²	0,1374 m ²
max(RSE) y	2,9797 m	3,0948 m
max(RSE) x	1,5949 m	1,5911 m

Tabelle 5.1: Varianz, Mittelwert und Maximalwert der Wurzel des quadratischen Fehlers für die Differenz zwischen Zustandsschätzung der Objekthypothese und den Referenzdaten einmal mit und einmal ohne nachträgliche Konturschätzung.

Zustandsgrößen führt (z. B. der Positionsschätzung). Sind zusätzlich Informationen über die Kontur für nachgelagerte Module von Bedeutung, so stellt die nachträgliche Konturschätzung eine notwendige Erweiterung des vorgestellten Filter-Verfahrens dar. Es werden Lagewinkel und Breite der Objekthypothese stabil verfolgt. Größere systematische Abweichungen sind auf Grund des ungünstigen Betrachtungswinkels bei der Schätzung der Länge festzustellen.




Bild 5.14: Darstellung der lateralen Positionsschätzung der Objekthypothese mit Konturschätzung (blau) und ohne Konturschätzung (grün gestrichelt) im Vergleich zu den Referenzdaten (rot).




Bild 5.15: Darstellung der longitudinalen Positionsschätzung der Objekthypothese mit Konturschätzung (blau) und ohne Konturschätzung (grün gestrichelt) im Vergleich zu den Referenzdaten (rot).




Bild 5.16: Darstellung der lateralen Geschwindigkeitsschätzung der Objekthypothese mit Konturschätzung (blau) und ohne Konturschätzung (grün gestrichelt) im Vergleich zu den Referenzdaten (rot).




Bild 5.17: Darstellung der longitudinalen Geschwindigkeitsschätzung der Objekthypothese mit Konturschätzung (blau) und ohne Konturschätzung (grün gestrichelt) im Vergleich zu den Referenzdaten (rot).




Bild 5.18: Darstellung des Lagewinkels der Objekthypothese mit Konturschätzung (blau) im Vergleich zu den Referenzdaten (rot).




Bild 5.19: Darstellung der Parameter Länge (blau) und Breite (schwarz gestrichelt) der Objekthypothese mit Konturschätzung im Vergleich zu den Referenzdaten (rot und rot gestrichelt).




Bild 5.20: Darstellung des normalisierten Fehlerquadrates für die laterale und die longitudinale Positions-schätzung der Objekthypothese mit (blau) und ohne (grün) Konturschätzung.

5.2.3 Folgeverhalten der Zustandsschätzung bei Vollbremsung der Objekthypothese

Die Filter-Eigenschaften bei einem nicht modellierten Verhalten der Objekthypothese werden im Folgenden betrachtet: Dem mit dem maschinellen Wahrnehmungssystem ausgestatteten Fahrzeug *kommt im Kreuzungsbereich ein Fahrzeug entgegen, das mit $8 \frac{m}{s^2}$ verzögert* (Bild 5.21).

Entfernungsabhängige Unsicherheit resultierend aus der Strahlgeometrie: Die laterale Position (Bild 5.22) wird durch die Vollbremsung des Objektes nicht beeinflusst. Signifikante Abweichungen sind im Bereich von 0s bis 1,5s zu erkennen, da in diesem Bereich die Unsicherheit durch die Strahlaufweitung erhöht wird. Bei der longitudinalen Positionsschätzung (Bild 5.23) ist eine leichte Abweichung der Schätzung von der Referenz ab 6s zu erkennen.

Erhöhte Zustandsunsicherheiten auf Grund der hohen Längsdynamik: Die laterale Geschwindigkeitsschätzung (Bild 5.24) wird durch die Vollbremsung des Objektes nicht beeinflusst. Bild 5.25 zeigt die longitudinale Geschwindigkeitsschätzung der Objekthypothese im Vergleich zu den Referenzdaten. Auffällig sind größere Abweichungen im Bereich von




Bild 5.21: Darstellung des Szenarios: Die Objekthypothese bewegt sich von vorne mit ca. $50 \frac{km}{h}$ auf dem geradeaus Fahrstreifen auf die Kreuzung zu und verzögert dann mit $8 \frac{m}{s^2}$ (Vollbremsung).

0s bis 2s und im Bereich von 4s bis 5,7s. Von 0s bis 2s resultiert die erhöhte Unsicherheit aus Einflüssen durch die Strahlaufweitung. Im Bereich von 4s bis 5,7s resultiert die Abweichung aus der starken Verzögerung des Objektes. Die Geschwindigkeitsschätzung der Objekthypothese folgt den Referenzdaten während der Verzögerung mit einem Versatz von $T_t = 0,3s$. Dies entspricht 5 Messzyklen des eingesetzten Sensors. Der zeitliche Versatz von 300ms beruht auf zwei Effekten: Der Erste ist auf die Eigenschaften des Messprinzips zurückzuführen (der Laserscanner misst lediglich Distanzen; die Geschwindigkeit bzw. Geschwindigkeitsänderungen ergeben sich erst über die Auswertung von zwei bzw. drei Distanzmessungen). Der Zweite resultiert aus den gewählten Dynamikmodellen: Modelliert sind lediglich Bewegungen mit konstanter Geschwindigkeit. Starke Änderungen der Geschwindigkeit sind in den Modellen nicht berücksichtigt und führen damit zu Modellverletzungen. Bild 5.26 zeigt, dass das normalisierte Fehlerquadrat trotz der im Modell nicht vorgesehenen starken Verzögerung nicht relevant ansteigt. Lediglich im Stillstand bei 6,5s gibt es bezüglich der lateralen Geschwindigkeitsschätzung eine kurze Phase in dem das normalisierte Fehlerquadrat deutlich erhöht ist. Ursache ist hier, dass kein Dynamikmodell für stehende Objekte vorhanden ist. Die Varianz, den Mittelwert und den Maximalwert der Wurzel des quadratischen Fehlers für die Differenz zwischen Zustandsschätzung der Objekthypothese und den Referenzdaten zeigt Tabelle 5.2. Die mittlere Richtigkeit der Positionsschätzung beträgt während der starken Verzögerung $0,27m$ (laterale Position) und $0,57m$ (longitudinale Position). Für die Geschwindigkeitsschätzung sind es $0,35 \frac{m}{s}$ (laterale Geschwindigkeit) bzw. $0,77 \frac{m}{s}$ (longitudinale Geschwindigkeit). Verzögert das Objekt voll, so liegt die Latenz des Filterverfahrens bei

300ms (5 Messzyklen).




Bild 5.22: Darstellung der lateralen Positionsschätzung der Objekthypothese (blau) im Vergleich zu den Referenzdaten (rot) bei einer Vollbremsung des Objektes.




Bild 5.23: Darstellung der longitudinalen Positionsschätzung der Objekthypothese (blau) im Vergleich zu den Referenzdaten (rot) bei einer Vollbremsung des Objektes.




Bild 5.24: Darstellung der lateralen Geschwindigkeitsschätzung der Objekthypothese (blau) im Vergleich zu den Referenzdaten (rot) bei einer Vollbremsung des Objektes.




Bild 5.25: Darstellung der longitudinalen Geschwindigkeitsschätzung der Objekthypothese (blau) im Vergleich zu den Referenzdaten (rot) bei einer Vollbremsung des Objektes.




Bild 5.26: Darstellung des normalisierten Fehlerquadrates für die laterale und die longitudinale Positions- und Geschwindigkeitsschätzung der Objekthypothese.

RMSE y	0,2734 m
RMSE x	0,5683 m
RMSE v_y	0,3544 $\frac{m}{s}$
RMSE v_x	0,7689 $\frac{m}{s}$
var(RSE) y	0,0690 m^2
var(RSE) x	0,0784 m^2
var(RSE) v_y	0,0807 $\frac{m^2}{s^2}$
var(RSE) v_x	0,9105 $\frac{m^2}{s^2}$
max(RSE) y	1,0809 m
max(RSE) x	1,4151 m
max(RSE) v_y	1,4485 $\frac{m}{s}$
max(RSE) v_x	3,2433 $\frac{m}{s}$

Tabelle 5.2: Varianz, Mittelwert und Maximalwert der Wurzel des quadratischen Fehlers für die Differenz zwischen Zustandsschätzung der Objekthypothese und den Referenzdaten.

5.2.4 Einsatz im realen Straßenverkehr

Bild 5.27 zeigt eine exemplarische Datensequenz aus den Evaluierungen des Systemes im realen Straßenverkehr über einem rektifizierten Luftbild. Das Szenario ist auf der Kreuzung Wohltberg-, Ecke Laagbergstraße in Wolfsburg aufgezeichnet worden. Die Kreuzung ist mit

einer Lichtsignalanlage versehen. Die jeweils gegenüberliegenden Kreuzungszweige befinden sich in der gleichen Lichtsignalphase. Das mit dem maschinellen Wahrnehmungssystem ausgestattete Fahrzeug wartet an der Haltelinie, während der Querverkehr in der Grünphase fährt. Dargestellt sind die Eingangsdaten des Laserscanners in Form von Strahlen. Diese sind farblich mit dem Status aus der Bewegungsklassifikation markiert. Den Farben sind hierbei folgende Bedeutungen zugeordnet:

- Dunkelblau: Beweglich
- Cyan: Potentiell beweglich
- Rot: Stationär
- Schwarz: Unbekannt

Werden die Ergebnisse der Bewegungsklassifikation in Bild 5.27 mit dem rektifizierten Luftbild verglichen, so wird eine korrekte Unterscheidung zwischen beweglichen Objekthypothesen und stationären Randbebauungshypothesen festgestellt. Durch Messunsicherheiten der eingesetzten Sensorik ist ein Fehler der Bewegungsklassifikation zu erkennen: Die Hauswand am linken oberen Rand der Kreuzung ist fälschlicherweise als beweglich bzw. potentiell beweglich klassifiziert worden. Die Entfernungsschätzungen des Laserscanners sind mit einem Kreis gekennzeichnet. Die Farbe dieses Kreises stellt das Ergebnis der Segmentierung dar. Entfernungsschätzungen gleicher Farbe sind dem gleichen Segment zugeordnet. Wird das Ergebnis der Segmentierung betrachtet, so wird eine korrekte Segmentierung festgestellt (vgl. Abschnitt 4.1.3). In weiß sind die Objekthypothesen mit ihren geschätzten Konturen und ihrem Geschwindigkeitsvektor abgebildet. Zu sehen sind vier Objekthypothesen.

5.2.5 Fazit

Es wird festgestellt, dass das vorgestellte Filterverfahren für die *Objektverfolgung in Kreuzungsbereichen geeignet* ist. Es ist in der Lage, ein quer einfahrendes Objekt über das Abbiegen bis zum Entfernen in Längsrichtung zu verfolgen. Die Unsicherheit von Positions- und Geschwindigkeitsschätzung hängt im Wesentlichen von der Entfernung der Objekthypothese zum Sensor und dem Aspektwinkel, unter dem die Objekthypothese beobachtet wird, ab. Dies deckt sich mit den theoretisch hergeleiteten Erwartungen (vgl. Abschnitt 2.2.2). Die geringste *Unsicherheit* wird daher bei orthogonaler Betrachtung der Objekthypothese relativ nah am Sensor festgestellt. Wird an konkrete Anwendungsfälle für den Einsatz des maschinellen Wahrnehmungssystems gedacht, so ergibt sich damit folgendes Bild: Je näher die Objekthypothese dem mit dem maschinellen Wahrnehmungssystem ausgestatteten Fahrzeug kommt und je kritischer somit die Situation wird, desto genauer wird auch das Ergebnis




Bild 5.27: Darstellung der Laserscanner-Entfernungsmessungen und der Objekthypothesen in urbaner Umgebung über einem rektifizierten Luftbild (der Aufnahmezeitpunkt von Luftbild und Sensordaten ist unterschiedlich, daher unterscheidet sich die Anzahl und Position der Fahrzeuge im Kreuzungsbereich. Beispielhafter Zustand der Objekthypothesen mit geschätzter Position, geschätztem Geschwindigkeitsvektor und der geschätzten Ausdehnung als graue Rechtecke abgebildet. Geschätzte Position des Ego Fahrzeuges in blau dargestellt. Die Laserscanner-Entfernungsmessungen sind gemäß dem Status der Bewegungsklassifikation farblich markiert: Dunkelblau: Beweglich, Cyan: Potentiell beweglich, Rot: Stationär und Schwarz: Unbekannt) ¹.

von Positions- und Entfernungsschätzung.

Die nachträgliche Konturschätzung ist dem Ansatz ohne nachträgliche Konturschätzung bezüglich Schätzgenauigkeit und des normalisierten Fehlerquadrats leicht überlegen. Die Vorteile, gegenüber einer Schätzung im Filterprozess, liegen hauptsächlich in einer Verringerung der Rechenkomplexität des Filterverfahrens. Die nachträgliche Konturschätzung wird nur für ausgewählte, relevante Objekthypothesen berechnet, um so die Rechenkomplexität zu minimieren. Ferner wird die Dimension des Zustandsvektors im Filter-Algorithmus minimiert, damit verringert sich auch die Dimension der während des Filterprozesses zu verwaltenden

¹Kartengrundlage: Orthophotomosaik 1000 der Stadt Wolfsburg, Geschäftsbereich IT - 15-3 GIS, 2008.

Matrizenoperation und der damit verbundenden Rechenkomplexität. Außerdem befriedigt die nachträgliche Konturschätzung den Bedarf nachgelagerter Module nach detaillierteren Konturinformationen.

Das vorgestellte Objektverfolgungssystem ist damit in urbanen Kreuzungsbereichen in der Lage, die Position der Objekthypothesen mit einem Mittelwert der Wurzel des quadratischen Fehlers von $0,2m$ bis $0,7m$ zu verfolgen. Da sich der maximale absolute Fehler des eingesetzten Sensorsystemes auf $\frac{\Delta r}{2} = 0,47m$ beläuft und sich dieser wie in Abschnitt 2.2.2 beschrieben noch weiter erhöht, entspricht dies den theoretisch erwarteten Werten. Die Geschwindigkeit wird mit einem Mittelwert der Wurzel des quadratischen Fehlers von $0,3\frac{m}{s}$ bis $0,8\frac{m}{s}$ geschätzt. Bei einer starken Verzögerung der Objekthypothese entsteht eine Totzeit von $T_t = 300ms$ bei der Erkennung der Verzögerung.

5.3 Fusion von objekt- und graphenbasierten Darstellungsformen

Bei der Analyse der Fusion von objekt- und graphenbasierter Darstellung wird zwischen zwei Szenarien unterschieden: Im Ersten wird ein konformes Verhalten der Verkehrsteilnehmer bezüglich der Straßenverkehrsordnung (vgl. Abschnitt 5.3.1) angenommen. Im Weiteren wird dann ein nicht vorgesehenes Verhalten angenommen (vgl. Abschnitt 5.3.2).




Bild 5.28: Grafische Darstellung der Gliederung von Kapitel 5.3

5.3.1 Konformes Verhalten bezüglich der Straßenverkehrsordnung

Die Eigenschaften der neuartigen Fusion von objekt- und graphenbasierten Darstellungsformen (AIMM-Filter) im Vergleich zu der aus der Literatur bekannten Implementierung des IMM-Filters werden im Folgenden evaluiert. Hierbei wird angenommen, dass sich die *Verkehrsteilnehmer gemäß der Straßenverkehrsordnung verhalten* und somit den, durch die Kreuzungstopologie vorgegebenen Verläufen der Fahrstreifen folgen.

Szenario: Querverkehr von rechts

Es wird ein Szenario mit *Querverkehr von rechts* analysiert (Bild 5.29).




Bild 5.29: Darstellung des Szenarios: Die Objekthypothese bewegt sich von rechts mit ca. $30 \frac{km}{h}$ auf die Kreuzung zu.

Unsicherheiten auf Grund eines ungünstigen Betrachtungswinkels: Bild 5.30 zeigt die longitudinale Positionsschätzung mittels AIMM- und IMM-Filter im Vergleich zu den Referenzdaten. Nennenswerte Abweichungen sind auf Grund des ungünstigen Aspektwinkels ausdrücklich im Bereich 0s bis 2s feststellbar, ansonsten unterscheiden sich die beiden Schätzungen nicht voneinander.

Konturpunktsprünge: Bild 5.31 zeigt die *laterale Positionsschätzung* mittels AIMM- und IMM-Filter im Vergleich zu den Referenzdaten. Abweichungen von der Referenz sind im Bereich von 3s bis 4s feststellbar, hier springt der Konturpunkt der Referenzdaten. Bild 5.32 zeigt die *longitudinale Geschwindigkeitsschätzung* mittels AIMM- und IMM-Filter im Vergleich zu den Referenzdaten. Im Bereich von 0s bis 3s zeigt die Schätzung des AIMM-Filters geringere Abweichungen von der Referenz als die Schätzung des IMM-Filters. Von 4s bis 7s hingegen sind die Ergebnisse gleichwertig.

Modellauswahl: Falsche Modellannahmen führen zu einer Unrichtigkeit in der Geschwindigkeitsschätzung des IMM-Filters im Bereich von 0s bis 3s. Die geringere Abweichung des AIMM-Filters resultiert daher aus der Vermeidung falscher Modellannahmen. Diese wird durch die Verwendung der zusätzlichen Informationsbasis des graphenbasierten Umfeldmodells möglich. Bild 5.33 zeigt die laterale Geschwindigkeitsschätzung mittels AIMM- und

IMM-Filter im Vergleich zu den Referenzdaten. Bei der Betrachtung fallen keine erheblichen Unterschiede zwischen den beiden Filter-Varianten auf. Bild 5.34 zeigt die vom AIMM- und IMM-Filter-Verfahren ausgewählten Dynamikmodelle im Vergleich zu den Referenzdaten. Auffällig sind hierbei eine fälschliche Annahme des Rechtsabbiege-Modelles bei 0,5s bis 1s und eine fälschliche Annahme des Linksabbiege-Modelles bei 2s durch das IMM-Filter. Beim neuartigen AIMM-Filter unterbleiben diese fälschlichen Annahmen, so dass das Geradeaus-Modell in diesem Bereich korrekt ausgewählt wird. Während des Rechtsabbiegens von 2,2s bis 5s erkennen beide Filter den Abbiegevorgang und wählen das Rechtsabbiege-Modell. Es fällt jedoch auf, dass das neue AIMM-Filter dies etwa 500ms eher erkennt als das IMM-Filter. Bild 5.35 zeigt die Wahrscheinlichkeit, mit der AIMM- und IMM-Filter das aktuell aktive Dynamikmodell auswählen und repräsentiert damit die Unsicherheit der Entscheidung. Die Wahrscheinlichkeit des Dynamikmodelles des AIMM-Filter liegt bei ungefähr 90%, im Bereich von 2,2s bis 3s liegt die Wahrscheinlichkeit bei 33%. In diesem Bereich befindet sich die Objekthypothese kurz vor der Kreuzung, die an dieser Stelle drei Verzweigungsmöglichkeiten bietet. Sobald die Sensordaten eine Bewegungsrichtung erkennen lassen, steigt die Auswahlwahrscheinlichkeit wieder auf ca. 90%. Die Auswahlwahrscheinlichkeit des IMM-Filters unterliegt auf Grund von Messunsicherheiten und -rauschen merklichen Schwankungen, die Auswahlwahrscheinlichkeit des AIMM-Filters wird entsprechend nicht so stark beeinflusst. Bild 5.36 zeigt das normalisierte Fehlerquadrat für die laterale und die longitudinale Positionsschätzung der Objekthypothese mit dem IMM- (grün) und dem AIMM-Filter (blau). Zwischen den beiden Filterverfahren sind keine Unterschiede zu erkennen. Auch bei der Geschwindigkeitsschätzung weisen beide Schätzungen ähnliche Werte auf (vgl. Bild 5.37). Das neue AIMM-Filter ist jedoch im Bereich von 0s bis 3s dem klassischen IMM-Filter bezüglich des normalisierten Fehlerquadrates deutlich überlegen. Tabelle 5.3 zeigt die Varianz, den Mittelwert und den Maximalwert der Wurzel des quadratischen Fehlers für die Differenz zwischen Zustandsschätzung der Objekthypothese und den Referenzdaten. Das AIMM-Filter ist dem IMM-Filter bei der longitudinalen Geschwindigkeitsschätzung (v_x) bezüglich aller drei Kriterien wesentlich überlegen. Für die übrigen Schätzfehler-Kriterien sind keine Unterschiede zwischen den beiden Filtern zu erkennen.




Bild 5.30: Darstellung der longitudinalen Positionsschätzung der Objekthypothese mittels AIMM- (blau) und IMM-Filter (grün) im Vergleich zu den Referenzdaten (rot).




Bild 5.31: Darstellung der lateralen Positionsschätzung der Objekthypothese mittels AIMM- (blau) und IMM-Filter (grün) im Vergleich zu den Referenzdaten (rot).




Bild 5.32: Darstellung der longitudinalen Geschwindigkeitsschätzung der Objekthypothese mittels AIMM- (blau) und IMM-Filter (grün) im Vergleich zu den Referenzdaten (rot).




Bild 5.33: Darstellung der lateralen Geschwindigkeitsschätzung der Objekthypothese mittels AIMM-Filter (blau) und IMM-Filter (grün) im Vergleich zu den Referenzdaten (rot).




Bild 5.34: Darstellung der Dynamikmodellauswahl des AIMM- (blau) und des IMM-Filters (grün) im Vergleich zu den Referenzdaten (rot).




Bild 5.35: Darstellung der Modellwahrscheinlichkeiten des AIMM-EKF (blau) im Vergleich mit denen des IMM-EKF (grün).




Bild 5.36: Darstellung des normalisierten Fehlerquadrates für die laterale und die longitudinale Positionsschätzung der Objekthypothese mit dem IMM-Filter (grün) und dem AIMM-Filter (blau).




Bild 5.37: Darstellung des normalisierten Fehlerquadrates für die laterale und die longitudinale Geschwindigkeitsschätzung der Objekthypothese mit dem IMM-Filter (grün) und dem AIMM-Filter (blau).

	IMM	AIMM
RMSE y	0,4513 m	0,5300 m
RMSE x	0,4352 m	0,5153 m
RMSE v_y	0,3795 $\frac{m}{s}$	0,3855 $\frac{m}{s}$
RMSE v_x	0,7999 $\frac{m}{s}$	0,4932 $\frac{m}{s}$
var(RSE) y	0,2570 m^2	0,3060 m^2
var(RSE) x	0,1624 m^2	0,2140 m^2
var(RSE) v_y	0,0656 $\frac{m^2}{s}$	0,0822 $\frac{m^2}{s}$
var(RSE) v_x	0,5159 $\frac{m^2}{s}$	0,1512 $\frac{m^2}{s}$
max(RSE) y	1,9079 m	1,7073 m
max(RSE) x	1,5136 m	1,4820 m
max(RSE) v_y	1,3936 $\frac{m}{s}$	1,4255 $\frac{m}{s}$
max(RSE) v_x	2,9817 $\frac{m}{s}$	1,5471 $\frac{m}{s}$

Tabelle 5.3: Varianz, Mittelwert und Maximalwert der Wurzel des quadratischen Fehlers für die Differenz zwischen Zustandsschätzung der Objekthypothese und den Referenzdaten, einmal mittels des IMM-Filters und einmal mittels des AIMM-Filters.

Szenario: Linksabbiegender Längsverkehr

Im Weiteren wird ein Szenario mit *linksabbiegender Längsverkehr* evaluiert (Bild 5.38).

Unsicherheiten auf Grund eines ungünstigen Betrachtungswinkels: Bild 5.40 zeigt die laterale Positionsschätzung mittels AIMM- und IMM-Filter im Vergleich zu den Referenzdaten. Signifikante Abweichungen sind für beide Filter auf Grund des ungünstigen Aspektwinkels von 0s bis 2s zu beobachten. Bild 5.41 zeigt die longitudinale Geschwindigkeitsschätzung. Nennenswerte Abweichungen sind für beide Filter auf Grund des ungünstigen Aspektwinkels ab 10s zu beobachten.

Konturpunktsprünge: Für die laterale Positionsschätzung (Bild 5.40) sind Abweichungen während des Konturpunktsprunges von 8s bis 11s zu beobachten. Bezüglich des normalisierten Fehlerquadrats der Positionsschätzung unterscheiden sich das IMM- und das AIMM-Filter nicht erheblich (vgl. Bild 5.45).

Modellauswahl: Auffällig sind bedeutsame Abweichungen von der Referenz bei der lateralen Geschwindigkeitsschätzung (Bild 5.42) des IMM-Filters bei 0,7s, bei 4s, von 5s bis 6s und von 6,3s bis 7s. Ursache hierfür sind falsche Modellannahmen. Das neue AIMM-Filter weist in diesen Bereichen wesentlich geringere Abweichungen auf, hier werden falsche Modellannahmen an den betreffenden Stellen vermieden. Bild 5.43 zeigt die vom AIMM und




Bild 5.38: Darstellung des Szenarios: Die Objekthypothese bewegt sich von vorne mit $\text{ca. } 30 \frac{\text{km}}{\text{h}}$ auf dem Linksabbiege-Fahrbereich auf die Kreuzung zu und biegt dann links ab.

IMM-Filter ausgewählten Dynamikmodelle im Vergleich zu den Referenzdaten. Auffällig sind beim IMM-Filter die fälschlichen Annahmen des Rechtsabbiege-Modelles bei 4s und von 6,3s bis 7s und die fälschlichen Annahmen des Linksabbiege-Modelles bei 0,7s und von 5s bis 6s. Beim AIMM-Filter unterbleiben diese fälschlichen Annahmen, das Geradeaus-Modell wird in diesem Bereich korrekt ausgewählt. Während des Linksabbiegens des Objektes von 8s bis 11s erkennen beide Filter den Abbiegevorgang und wählen das Linkssabbiege-Modell. Es fällt jedoch auf, dass das neue AIMM-Filter dies etwa 500ms eher erkennt als das klassische IMM-Filter. Bild 5.44 zeigt die Wahrscheinlichkeit mit der AIMM- und IMM-Filter das aktuell aktive Dynamikmodell auswählen und repräsentiert damit die Unsicherheit der Entscheidung. Die Auswahlwahrscheinlichkeit des Dynamikmodelles des AIMM-Filters liegt bei ungefähr 97%, im Bereich von 8s bis 8,2s liegt die Wahrscheinlichkeit bei 66%. Die Auswahlwahrscheinlichkeit des IMM-Filters unterliegt auf Grund von Messunsicherheiten und -rauschen merklichen Schwankungen. Bild 5.46 zeigt, dass bei 10,2s das normalisierte Fehlerquadrat der lateralen Geschwindigkeitsschätzung des IMM-Filters deutlich ansteigt, dies wird durch das neue AIMM-Filter vermieden. Überdies ist das AIMM-Filter im Bereich von 4s bis 7s dem IMM-Filter bezüglich des normalisierten Fehlerquadrates überlegen. Tabelle 5.4 zeigt die Schätzrichtigkeit des IMM- und des AIMM-Filters im Vergleich. Bezüglich des Mittelwerts der Wurzel des quadratischen Fehlers für die laterale und die longitudinale Positionsschätzung und die laterale Geschwindigkeitsschätzung ist das neue AIMM-Filter leicht überlegen. Deutliche Unterschiede zwischen den beiden Filtern werden nicht festgestellt.

Es wird damit festgestellt, dass das AIMM-EKF bei konformem Verhalten der Verkehrsteilnehmer eine frühere und stabilere Erkennung der korrekten Dynamikmodelle ermöglicht. Die Modelle wechseln früher (ca. 500 ms) in den neuen Zustand und verlassen diesen auch früher wieder. Außerdem ist die Modellwahrscheinlichkeit deutlich stabiler. Das hat den positiven Effekt, dass falsche Modellannahmen deutlich reduziert werden, dies wird unter anderem in der Qualität und dem normalisierten Fehlerquadrat der Geschwindigkeitsschätzung deutlich.




Bild 5.39: Darstellung der longitudinalen Positionsschätzung der Objekthypothese mittels AIMM- (blau) und IMM-Filter (grün) im Vergleich zu den Referenzdaten (rot).




Bild 5.40: Darstellung der lateralen Positionsschätzung der Objekthypothese mittels AIMM- (blau) und IMM-Filter (grün) im Vergleich zu den Referenzdaten (rot).




Bild 5.41: Darstellung der longitudinalen Geschwindigkeitsschätzung der Objekthypothese mittels AIMM- (blau) und IMM-Filter (grün) im Vergleich zu den Referenzdaten (rot).




Bild 5.42: Darstellung der lateralen Geschwindigkeitsschätzung der Objekthypothese mittels AIMM- (blau) und IMM-Filter (grün) im Vergleich zu den Referenzdaten (rot).




Bild 5.43: Darstellung der Dynamikmodellauswahl des AIMM- (blau) und des IMM-Filter (grün) im Vergleich zu den Referenzdaten (rot).




Bild 5.44: Darstellung der Modellwahrscheinlichkeiten des AIMM- (blau) im Vergleich mit denen des IMM-Filters (grün).




Bild 5.45: Darstellung des normalisierten Fehlerquadrates für die laterale und die longitudinale Positionsschätzung der Objekthypothese mit dem IMM-Filter (grün) und dem AIMM-Filter (blau).




Bild 5.46: Darstellung des normalisierten Fehlerquadrates für die laterale und die longitudinale Geschwindigkeitsschätzung der Objekthypothese mit dem IMM-Filter (grün) und dem AIMM-Filter (blau).

	IMM	AIMM
RMSE y	0,7161 m	0,6743 m
RMSE x	0,2778 m	0,2706 m
RMSE v_y	0,5784 $\frac{m}{s}$	0,4453 $\frac{m}{s}$
RMSE v_x	0,2928 $\frac{m}{s}$	0,3152 $\frac{m}{s}$
var(RSE) y	0,3767 m^2	0,4530 m^2
var(RSE) x	0,0278 m^2	0,0217 m^2
var(RSE) v_y	0,5033 $\frac{m^2}{s}$	0,3862 $\frac{m^2}{s}$
var(RSE) v_x	0,2039 $\frac{m^2}{s}$	0,3028 $\frac{m^2}{s}$
max(RSE) y	3,4539 m	3,5358 m
max(RSE) x	0,8947 m	0,9127 m
max(RSE) v_y	3,7053 $\frac{m}{s}$	3,4191 $\frac{m}{s}$
max(RSE) v_x	2,3556 $\frac{m}{s}$	2,7072 $\frac{m}{s}$

Tabelle 5.4: Varianz, Mittelwert und Maximalwert der Wurzel des quadratischen Fehlers für die Differenz zwischen Zustandsschätzung der Objekthypothese und den Referenzdaten, einmal mittels des IMM-Filters und einmal mittels des AIMM-Filters.

5.3.2 Nicht konformes Verhalten bezüglich der Straßenverkehrsordnung

Im Folgenden wird nun angenommen, dass die Verkehrsteilnehmer nicht den durch die Kreuzungstopologie vorgegebenen Verläufen der Fahrstreifen folgen und sich damit nicht gemäß der Straßenverkehrsordnung verhalten.

Szenario: Von Rechtsabbiegerfahrstreifen links abbiegen

Es wird ein Szenario analysiert, in dem sich das *Objekt erst auf dem Rechtsabbiege-Fahrstreifen befindet, um dann aber links abzubiegen* (Bild 5.47).




Bild 5.47: Darstellung des Szenarios: Die Objekthypothese bewegt sich von vorne mit ca. $30 \frac{km}{h}$ auf dem Rechtsabbiege-Fahrstreifen auf die Kreuzung zu und biegt dann auf der Kreuzung links ab.

Entfernungsabhängige Unsicherheit resultierend aus der Strahlgeometrie: Bild 5.51 zeigt die longitudinale Geschwindigkeitsschätzung der Objekthypothese. Signifikante Abweichungen sind auf Grund der Unsicherheit durch die Strahlaufweitung von 10s bis 14s zu erkennen. Hier zeigt die Schätzung des AIMM-Filters deutlich geringere Abweichungen von den Referenzdaten. Im übrigen Beobachtungszeitraum zeigen beide Schätzungen vergleichbare Ergebnisse.

Konturpunktsprünge: Beide Filter weisen während der Konturpunktsprünge erhöhte normalisierte Fehlerquadrat-Werte auf (vgl. Bild 5.54), verfolgen die Objekthypothese aber die restliche Zeit mit niedrigeren Werten.

Modellauswahl: Bild 5.48 zeigt die longitudinale Positionsschätzung der Objekthypothese. Leichte Abweichungen sind im Bereich von 12s bis 14s zu erkennen. Diese sind durch eine fehlerhafte Modellauswahl verursacht. Bild 5.49 zeigt die laterale Positionsschätzung der Objekthypothese. Abweichungen sind im Bereich von 9s bis 14s zu erkennen. Ein Unterschied zwischen AIMM- (blau) und IMM-Filter (grün) ist in beiden Fällen nicht erkennbar. Bild 5.52 zeigt, dass die Dynamikmodellauswahl des AIMM-Filters trotz des nicht konformen Verhaltens bezüglich der Straßenverkehrsordnung korrekt funktioniert. Das Linksabbiege-Modell wird mit einem zeitlichen Versatz von ca. 500ms korrekt aktiviert. Eine falsche Modellannahme ist bei 10,5s zu erkennen. Ursache ist ein Fehler in der Positionierung auf dem graphenbasierten Umfeldmodell. Dieser resultiert aus Unsicherheiten der Positionsschätzung. Das IMM-Filter trifft auf Grund des Messrauschens und den nicht optimal gewählten Übergangswahrscheinlichkeiten über den gesamten Beobachtungszeitraum eine Vielzahl fehlerhafter Modellauswahlentscheidungen. Bild 5.55 zeigt, dass bei 10s und bei 12s zunächst die laterale und später die longitudinale Geschwindigkeitsschätzung des IMM-Filters erhöhte normalisierte Fehlerquadrat-Werte aufweist. Dies wird durch das neue AIMM-Filter vermieden. Weiterhin ist das AIMM-Filter im Bereich von 1s bis 7s und von 13s bis 14s dem IMM-Filter bezüglich des normalisierten Fehlerquadrates überlegen. Tabelle 5.5 zeigt, dass das neue AIMM- dem IMM-Filter bezüglich der Richtigkeit der Geschwindigkeitsschätzung nennenswert überlegen ist. Bezüglich der übrigen Kriterien sind leichte Vorteile des AIMM- gegenüber dem IMM-Filter zu verzeichnen. Erhebliche Abweichungen werden jedoch nicht festgestellt.

Es wird die Überlegenheit des neuen AIMM-Filters auch für den Fall des unvorhergesehenen Abbiegens festgestellt. Die Wahrscheinlichkeit des Dynamikmodelles des AIMM-Filters liegt bei ungefähr 95% (Bild 5.44). Zwischenzeitlich gibt es auf Grund erhöhter Unsicherheiten bei der Positionierung auf dem graphenbasierten Umfeldmodell einige Modellauswahlentscheidungen mit erhöhter Unsicherheit. Die Modellauswahlentscheidung des IMM-Filters wird über den gesamten Beobachtungszeitraum mit stark schwankenden Wahrscheinlichkeiten getroffen.




Bild 5.48: Darstellung der longitudinalen Positionsschätzung der Objekthypothese mittels AIMM- (blau) und IMM-Filter (grün) im Vergleich zu den Referenzdaten (rot).




Bild 5.49: Darstellung der lateralen Positionsschätzung der Objekthypothese mittels AIMM- (blau) und IMM-Filter (grün) im Vergleich zu den Referenzdaten (rot).




Bild 5.50: Darstellung der longitudinalen Geschwindigkeitsschätzung der Objekthypothese mittels AIMM- (blau) und IMM-Filter (grün) im Vergleich zu den Referenzdaten (rot).




Bild 5.51: Darstellung der lateralen Geschwindigkeitsschätzung der Objekthypothese mittels AIMM- (blau) und IMM-Filter (grün) im Vergleich zu den Referenzdaten (rot).




Bild 5.52: Darstellung der Dynamikmodellauswahl des AIMM-Filters (blau) im Vergleich zu den Referenzdaten (rot).




Bild 5.53: Darstellung der Modellwahrscheinlichkeiten des IMM-Filters (grün) und des AIMM-Filters (blau).




Bild 5.54: Darstellung des normalisierten Fehlerquadrates für die laterale und die longitudinale Positionsschätzung der Objekthypothese mit dem IMM-Filter (grün) und dem AIMM-Filter (blau).




Bild 5.55: Darstellung des normalisierten Fehlerquadrates für die laterale und die longitudinale Geschwindigkeitsschätzung der Objekthypothese mit dem IMM-Filter (grün) und dem AIMM-Filter (blau).

Szenario: Wendemanöver im Kreuzungsbereich (U-Turn)

Es wird nun ein Szenario mit einem Wendemanöver untersucht. Das *Objekt nähert sich in Längsrichtung der Kreuzung und wendet dann mit einem U-Turn* (Bild 5.56).

	IMM	AIMM
RMSE y	1,0796 m	0,9872 m
RMSE x	0,4835 m	0,4533 m
RMSE v_y	0,8673 $\frac{m}{s}$	0,5389 $\frac{m}{s}$
RMSE v_x	0,7750 $\frac{m}{s}$	0,5071 $\frac{m}{s}$
var(RSE) y	0,7581 m^2	0,7408 m^2
var(RSE) x	0,2331 m^2	0,1869 m^2
var(RSE) v_y	0,8329 $\frac{m^2}{s}$	0,4702 $\frac{m^2}{s}$
var(RSE) v_x	0,9569 $\frac{m^2}{s}$	0,3485 $\frac{m^2}{s}$
max(RSE) y	2,9390 m	2,9585 m
max(RSE) x	2,1690 m	2,1099 m
max(RSE) v_y	4,2454 $\frac{m}{s}$	3,9237 $\frac{m}{s}$
max(RSE) v_x	4,8661 $\frac{m}{s}$	4,8999 $\frac{m}{s}$

Tabelle 5.5: Varianz, Mittelwert und Maximalwert der Wurzel des quadratischen Fehlers für die Differenz zwischen Zustandsschätzung der Objekthypothese und den Referenzdaten, einmal mittels des IMM-Filters und einmal mittels des AIMM-Filters.

Entfernungsabhängige Unsicherheit resultierend aus der Strahlgeometrie: Bild 5.60 zeigt die laterale Geschwindigkeitsschätzung der Objekthypothese. Bedeutsame Abweichungen sind auf Grund der Unsicherheit durch die Strahlaufweitung von 0s bis 8s zu erkennen. Hier zeigt die Schätzung des AIMM-Filters eine deutlich geringere Abweichungen von den Referenzdaten. Von 12s bis 14s weichen beide Schätzungen ähnlich stark von den Referenzdaten ab. Im übrigen Beobachtungszeitraum zeigen beide Schätzungen vergleichbare Ergebnisse.

Konturpunktsprünge: Bezüglich des normalisierten Fehlerquadrats der Positionsschätzung unterscheiden sich das IMM- und das AIMM-Filter nicht (vgl. Bild 5.54).

Modellauswahl: Bild 5.61 zeigt die Modellauswahl des AIMM- (blau) und des IMM-Filters (grün) im Vergleich zu den Referenzdaten (rot). Von 0s bis 8s liefert das AIMM-Filter die besseren Ergebnisse. Auf Grund des Messrauschens und nicht optimal gewählter Übergangswahrscheinlichkeiten trifft das IMM-Filter in diesem Bereich eine Vielzahl falscher Modellauswahlentscheidungen. Das Wendemanöver wird von beiden Filtern ca. 500ms nach Beginn erkannt. Das IMM-Filter erkennt das Wendemanöver mit einer Ausnahme bei 12s korrekt. Die Ausholbewegungen bei 9s bis 11s und von 15s bis 17s werden jedoch nicht erkannt. Das AIMM-Filter erkennt das Wendemanöver nicht korrekt. Die Modellauswahl springt häufig zwischen gerade und rechts. Ab 17s wählen beide Filter das korrekte gerade-




Bild 5.56: Darstellung des Szenarios: Die Objekthypothese bewegt sich von vorne mit ca. $30 \frac{km}{h}$ auf dem Linksabbiege-Fahrstreifen auf die Kreuzung zu und wendet dann in einem U-Turn auf der Kreuzung.

aus Modell. Bild 5.62 zeigt, dass die Auswahlentscheidung des AIMM-Filters (blau) von 0s bis 8s deutlich sicherer ist als die des IMM-Filters (grün). Im Bereich des Wendemanövers von 9s bis 17s sind die (falschen) Entscheidungen des AIMM-Filters mit einer großen Unsicherheit behaftet. Das IMM-Filter wählt in diesem Bereich mit einer Wahrscheinlichkeit von 90% das richtige Modell aus. Bild 5.55 zeigt, dass bei 4s und bei 14s das normalisierte Fehlerquadrat der lateralen Geschwindigkeitsschätzung des IMM-Filters erhöhte Werte aufweist. Dies wird durch das neue AIMM-Filter vermieden. Zudem ist das AIMM-Filter im Bereich von 1s bis 7s dem IMM-Filter bezüglich des normalisierten Fehlerquadrates überlegen. Ein erhöhtes normalisiertes Fehlerquadrat der lateralen Geschwindigkeitsschätzung ist bei 13s wird von beiden Filtern nicht vermieden. Tabelle 5.5 zeigt, dass das neue AIMM- dem IMM-Filter bezüglich der Richtigkeit der Geschwindigkeitsschätzung deutlich überlegen ist. Bezüglich der übrigen Kriterien sind leichte Vorteile des AIMM- gegenüber dem IMM-Filters zu verzeichnen. Wesentliche Abweichungen werden jedoch nicht festgestellt.

Es wird festgestellt: Für Manöver, in denen von Fahrstreifen in nicht vorgesehene Richtungen abgelenkt wird, entsteht kein Unterschied bei der Erkennung des Manöverwechsels. Bei einem U-Turn-Wendemanöver der Objekthypothese kommt es zu einer Vielzahl von Modellauswahl-Fehlentscheidungen. Auf Grund der hohen Unsicherheit dieser Entscheidungen sind jedoch keine Nachteile bezüglich der Richtigkeit der Zustandsschätzung nachweisbar.




Bild 5.57: Darstellung der longitudinalen Positionsschätzung der Objekthypothese mittels AIMM- (blau) und IMM-Filter (grün) im Vergleich zu den Referenzdaten (rot).




Bild 5.58: Darstellung der lateralen Positionsschätzung der Objekthypothese mittels AIMM- (blau) und IMM-Filter (grün) im Vergleich zu den Referenzdaten (rot).




Bild 5.59: Darstellung der longitudinalen Geschwindigkeitsschätzung der Objekthypothese mittels AIMM- (blau) und IMM-Filter (grün) im Vergleich zu den Referenzdaten (rot).




Bild 5.60: Darstellung der lateralen Geschwindigkeitsschätzung der Objekthypothese mittels AIMM- (blau) und IMM-Filter (grün) im Vergleich zu den Referenzdaten (rot).




Bild 5.61: Darstellung der Dynamikmodellauswahl des AIMM- (blau) und des IMM-Filters (grün) im Vergleich zu den Referenzdaten (rot).




Bild 5.62: Darstellung der Modellwahrscheinlichkeiten des AIMM-Filters (blau) im Vergleich mit denen des IMM-Filters (grün).




Bild 5.63: Darstellung des normalisierten Fehlerquadrates für die laterale und die longitudinale Positionsschätzung der Objekthypothese mit dem IMM-Filter (grün) und dem AIMM-Filter (blau).




Bild 5.64: Darstellung des normalisierten Fehlerquadrates für die laterale und die longitudinale Geschwindigkeitsschätzung der Objekthypothese mit dem IMM-Filter (grün) und dem AIMM-Filter (blau).

	IMM	AIMM
RMSE y	0,4989 m	0,4589 m
RMSE x	0,4514 m	0,4622 m
RMSE v_y	0,8209 $\frac{m}{s}$	0,4291 $\frac{m}{s}$
RMSE v_x	0,3201 $\frac{m}{s}$	0,2685 $\frac{m}{s}$
var(RSE) y	0,2026 m^2	0,1820 m^2
var(RSE) x	0,1224 m^2	0,1162 m^2
var(RSE) v_y	0,9443 $\frac{m^2}{s}$	0,3510 $\frac{m^2}{s}$
var(RSE) v_x	0,1061 $\frac{m^2}{s}$	0,1057 $\frac{m^2}{s}$
max(RSE) y	2,8199 m	2,6125 m
max(RSE) x	1,4829 m	1,5326 m
max(RSE) v_y	4,6643 $\frac{m}{s}$	3,1335 $\frac{m}{s}$
max(RSE) v_x	1,9962 $\frac{m}{s}$	2,1719 $\frac{m}{s}$

Tabelle 5.6: Varianz, Mittelwert und Maximalwert der Wurzel des quadratischen Fehlers für die Differenz zwischen Zustandsschätzung der Objekthypothese und den Referenzdaten, einmal mittels des IMM-Filters und einmal mittels des AIMM-Filters.

5.3.3 Fazit

Das neue AIMM-Filter ermöglicht bei Verkehrsregel-konformem Verhalten der Verkehrsteilnehmer eine frühere und stabilere Erkennung der korrekten Dynamikmodelle. Die Modelle wechseln früher (ca. 500ms) in den neuen Zustand und verlassen diesen auch früher wieder.

Für Manöver, in denen gemäß der Fahrstreifenmarkierungen in nicht vorgesehene Richtungen abgebogen wird, entsteht zwischen AIMM- und IMM-Filter kein nennenswerter Unterschied bei der Erkennung des Manöverwechsels. Falsche Modellannahmen des AIMM-Filters oder erhöhte Unsicherheiten in der Modellauswahl und damit in der Zustandsschätzung werden nicht festgestellt.

Eine Herausforderung stellt hingegen das Verhalten bei einem Wendemanöver im Kreuzungsbereich dar. Vor dem Wendemanöver holt das Objekt etwas aus, dadurch kommt es nach rechts und wird auf jedem Kreuzungsast dem Rechtsabbiege-Fahrstreifen zugeordnet. Obwohl das Objekt eine Wende linksherum ausführt, was auch von den Sensordaten erkannt und gestützt wird (das IMM-Filter erkennt das Manöver korrekt), liefert das graphenbasierte Umfeldmodell auf Grund der falschen Zuordnung die Information eines Rechtsabbiege-Manövers. Dies resultiert in einer erhöhten Unsicherheit der Modellauswahl und einer Vielzahl von Modellwechseln beim AIMM-Filter.

Tabelle 5.7 zeigt, dass über alle Szenarien gemittelt das neue AIMM- dem IMM-Filter bezüglich nahezu aller Kriterien überlegen ist. Bedeutsam ist die Überlegenheit des AIMM- gegenüber dem klassischen IMM-Filter bezüglich der Qualität der Geschwindigkeitsschätzung.

	IMM	AIMM
RMSE y	0,6864 m	0,6626 m
RMSE x	0,4120 m	0,4254 m
RMSE v_y	0,6615 $\frac{m}{s}$	0,4497 $\frac{m}{s}$
RMSE v_x	0,5470 $\frac{m}{s}$	0,3960 $\frac{m}{s}$
var(RSE) y	0,3985 m^2	0,4205 m^2
var(RSE) x	0,1364 m^2	0,1347 m^2
var(RSE) v_y	0,5865 $\frac{m^2}{s}$	0,3224 $\frac{m^2}{s}$
var(RSE) v_x	0,4457 $\frac{m^2}{s}$	0,2271 $\frac{m^2}{s}$
max(RSE) y	2,7802 m	2,7035 m
max(RSE) x	1,5151 m	1,5101 m
max(RSE) v_y	3,5022 $\frac{m}{s}$	2,9755 $\frac{m}{s}$
max(RSE) v_x	3,0499 $\frac{m}{s}$	2,8315 $\frac{m}{s}$

Tabelle 5.7: Varianz, Mittelwert und Maximalwert der Wurzel des quadratischen Fehlers für die Differenz zwischen Zustandsschätzung der Objekthypothese und den Referenzdaten, einmal mittels des IMM-Filters und einmal mittels des AIMM-Filters gemittelt über alle Szenarien.

5.4 Fusion von objekt- und gitterbasierten Darstellungsformen: Initialisierungsverhalten

Das Initialisierungsverhalten des Filters wird im folgenden Szenario betrachtet: Dem mit dem maschinellen Wahrnehmungssystem ausgestatteten Fahrzeug *kommt im Kreuzungsreich ein Fahrzeug entgegen* (Bild 5.65). Für die Schätzung der longitudinalen und der lateralen Position ergeben sich mit der Initialisierung aus der Geschwindigkeitshistorie keine messbaren Veränderungen. Der Grund liegt in dem hohen Vertrauen, mit dem die Distanzmessungen des Laserscanners in die Schätzung des Kalman-Filters eingehen. Deshalb wird die Position schon mit der ersten Messung geschätzt, eine weitere Verringerung der Detektionslatenz ist hier nicht möglich.

Die Bilder 5.66 und 5.67 zeigen die longitudinale und die laterale Geschwindigkeitsschätzung mittels Initialisierung ohne Geschwindigkeitshistorie (Schätzwert blau gestrichelt, Va-




Bild 5.65: Darstellung des Szenarios: Die Objekthypothese bewegt sich von vorne mit ca. $30 \frac{km}{h}$ auf dem Geradeaus-Fahrbahnen auf die Kreuzung zu. Das Objekt ist hierbei bis zu einer Entfernung von ca. 50m verdeckt und somit erst ab dieser Entfernung detektierbar.

rianz schwarz gestrichelt) und Initialisierung mit Geschwindigkeitshistorie (Schätzwert blau, Varianz schwarz). Verhalten sich neu initialisierte Objekthypothesen und vergangene Objekthypothesen ähnlich, so wird eine Geschwindigkeitshypothese mit der 2. Entfernungsmessung (nach $T_{cr} = T_{cs} = 120ms$) bestätigt und die Objekthypothese initialisiert. Die Initialisierung ohne zusätzliche Informationen findet erst zwei Zyklen später (mit der 4. Messung, nach $T_{cr} = 240ms$) eine Annäherung an die Schätzung mit zusätzlichen Informationen statt. Eine komplette Annäherung findet vier Messungen später (mit der 6. Messung, nach $T_{cs} = 360ms$) statt.

Aus diesen Ergebnissen ergibt sich die Fragestellung, wieviel Information sich statistisch in der Geschwindigkeitshistorie ansammelt. Hierfür werden 15 Szenarien mit einer Länge von 1 Minute bis zu 3 Minuten und 30 Sekunden ausgewertet. Untersucht wird, wie viele der initialisierten Objekthypothesen von dem in Abschnitt 4.3 vorgestellten Verfahren zur beschleunigten Initialisierung von Objekthypothesen profitieren.

Im Mittel profitieren 8,16% der initialisierten Objekthypothesen von dem vorgeschlagenen Verfahren. Maximal sind es 11,69% (Szenario 5), minimal 2,17% (Szenario 14). Ist eine höhere Quote gewünscht, so ist es zielführend die *Information der Geschwindigkeitshistorie* zu erweitern (z. B. um Extended Floating Car Data). Die Schwankungen der Ergebnisse sind durch Abhängigkeiten von der Verkehrsdichte und von der Betrachtungsdauer der Kreuzung zu erklären.

zungssituation verursacht. Letztere ist speziell von der Wartezeit vor der Einfahrt in die Kreuzung und eventuellen Verdeckungen des Sichtbereichs abhängig.

Fazit

Wird eine Objekthypothese an einer Stelle initialisiert, an der schon vorher ein Objekt detektiert worden ist und verhält es sich ähnlich, so verringert sich die Detektionslatenz um 50% von vier ($T_{cr} = 240\text{ms}$) auf zwei ($T_{cr} = 120\text{ms}$) Zyklen. Objekthypothesen, die von der verbesserten Initialisierung profitieren (8,16 % aller initialisierten Objekthypothesen), werden somit eher ausgegeben, als solche, die wie bisher initialisiert wurden. Eine weitere Verringerung der Detektionslatenz auf einen Zyklus ist für einen Entfernungen messenden Sensor nicht möglich. Es sind mindestens zwei Messungen notwendig um eine Geschwindigkeitshypothese zu bestätigen.




Bild 5.66: Darstellung der longitudinalen Geschwindigkeitsschätzung der Objekthypothese mittels Initialisierung ohne Geschwindigkeitshistorie (Schätzwert blau gestrichelt, Varianz schwarz gestrichelt) und Initialisierung mit Geschwindigkeitshistorie (Schätzwert blau, Varianz schwarz).




Bild 5.67: Darstellung der lateralen Geschwindigkeitsschätzung der Objekthypothese mittels Initialisierung ohne Geschwindigkeitshistorie (Schätzwert blau gestrichelt, Varianz schwarz gestrichelt) und Initialisierung mit Geschwindigkeitshistorie (Schätzwert blau, Varianz schwarz).

5.5 Ressourcenbedarf des Algorithmus

Bild 5.68 zeigt das Zeitverhalten des vorgestellten Algorithmus im Detail. Abgebildet ist das Zeitverhalten für eine exemplarische Sequenz aus einer Messfahrt im realen Straßenverkehr.

Szenario	Klassisch initialisiert		Neuartig initialisiert	
1	2760	90,73%	282	09,27%
2	3024	94,92%	162	05,08%
3	1617	94,89%	87	05,11%
4	2586	93,09%	192	06,91%
5	4350	88,31%	576	11,69%
6	1935	95,27%	96	04,73%
7	2226	90,38%	237	09,62%
8	3132	89,46%	369	10,54%
9	2859	88,49%	372	11,51%
10	2781	90,70%	285	09,30%
11	2058	96,89%	66	03,11%
12	1503	94,89%	81	05,11%
13	3129	88,54%	405	11,46%
14	1896	97,83%	42	02,17%
15	1602	95,53%	75	04,47%
mittel	2497	91,84%	222	08,16%
gesamt	37458	91,84%	3327	08,16%

Tabelle 5.8: Vergleich der Anzahl der klassischen Initialisierungen mit der Anzahl der neuartigen Initialisierung in 15 beispielhaften urbanen Szenarien.

Es handelt sich um eine Sequenz von der Kreuzung Wohltberg-, /Ecke Laagbergstraße in Wolfsburg. Zu sehen ist in lila die Anzahl der Objekthypothesen, diese schwankt zwischen 0 und 24 Objekthypothesen. Zusätzlich ist in blau der Zeitbedarf des Tracking-Algorithmus und in grün der Zeitbedarf der Visualisierung zu sehen. Für die Messung wird ein Standard-PC mit einem Intel Core 2 Duo E8400 Prozessor mit 3GHz verwendet. Die Visualisierung benötigt im Durchschnitt 5ms. Der eigentliche Objekttracking-Algorithmus benötigt maximal 2,7ms und minimal 0,5ms, im Durchschnitt sind es ca. 1ms. Hierbei ist der Zeitbedarf, erwartungsgemäß, mit der Anzahl der Objekthypothesen korreliert. An den Tracking-Algorithmus besteht der Anspruch eine Echtzeitfähigkeit zu gewährleisten. Dies ist der Fall, wenn der Algorithmus innerhalb eines Messzyklus (60ms) zu berechnen ist. Der vorgestellte Algorithmus arbeitet trotz des aufwändigeren Multi-Modell-Ansatzes (mit drei parallelen Modellen) effizient und unterbietet die Anforderungen an die Echtzeitfähigkeit. Einen Beitrag hierzu liefert unter anderem die Bewegungsklassifikation, die die Anzahl der Objekthypothesen im Tracking für eine belebte Kreuzung im Mittel auf 12 reduziert.




Bild 5.68: Zeitverhalten des vorgestellten Algorithmus im Detail: Die Anzahl der Objekte [Anzahl] (lila), der Zeitbedarf des Trackings [ms] (blau), der Zeitbedarf der Visualisierung [ms] (grün).

5.6 Anwendungsbeispiel

Im Folgenden wird ein Anwendungsbeispiel vorgestellt, das auf dem in dieser Arbeit vorgestellten maschinellen Wahrnehmungssystem basiert. Die Entwicklung der Applikation ist nicht Gegenstand dieser Arbeit gewesen und wird daher nicht ausführlich diskutiert.

Kreuzungsassistent

Der auf dem vorgestellten maschinellen Wahrnehmungssystem basierende Kreuzungsassistent besteht aus einem Assistenzsystem für das Linksabbiegen, für Rechtsabbiegen und für Rechts-vor-Links-Situationen. Die Realisierung eines Linksabbiege-Assistent belegt die Fähigkeit des maschinellen Wahrnehmungssystems Längsverkehr im urbanen Umfeld zu detektieren. Der Anwendungsfall Rechts-vor-Links-Assistenz belegt die grundsätzliche Eignung des Wahrnehmungssystems Querverkehr zu verfolgen. Die Detektion von Fahrrädern wird am Beispiel eines Rechtsabbiege-Assistenzsystems gezeigt. Die Assistenzsysteme sind sowohl im realen Straßenverkehr als auch auf dem Prüfgelände untersucht worden.

5.7 Fazit

Die Untersuchungen haben gezeigt, dass ein maschinelles Wahrnehmungssystem für urbane Kreuzungsszenarien basierend auf einem einzelnen seriennahen Laserscannern realisiert werden kann. Das vorgestellte maschinelle Wahrnehmungssystem hat sich in den referenzierten Testreihen auf dem Prüfgelände und in den praktischen Evaluierungen im realen Straßenverkehr bewährt und seine Leistungsfähigkeit unter Beweis gestellt. Es ist in der Lage, Objekthypothesen unterschiedlicher Konturformen (Fahrradfahrer und verschiedene Fahrzeuge) im Kreuzungsbereich stabil zu verfolgen. Es wird gezeigt, dass das vorgestellte Objektmodell invariant gegenüber Konturabweichungen ist und sowohl Längs- als auch Querverkehr ohne eine anfällige Fallunterscheidung verfolgt.

Querdynamische Manöver werden in einem neuartigen Ansatz zur Fusion objekt- und graphenbasierter Darstellungsformen berücksichtigt und somit die Schätzgenauigkeit des Filters z. B. für die Geschwindigkeit signifikant verbessert. Hierbei führt die individuelle Anpassung der Übergangsmatrix zur Laufzeit auf der Basis von Navigationskartendaten *individuell für jede Objekthypothese* zu einer früheren, korrekten Manövererkennung. Dies ermöglicht es, die Anzahl der Filterzustände außerhalb der Akzeptanzregion, insbesondere bei der Geschwindigkeitsschätzung, deutlich zu reduzieren. Das Verfahren funktioniert sowohl unter der Randbedingung, dass sich die Objekthypothesen konform zu den Verkehrsregeln verhalten als auch im Falle eines unerwarteten Verhaltens der Verkehrsteilnehmer.

Die nachträgliche Konturschätzung schafft es, detaillierte Konturinformationen recheneffizient zu schätzen. Eventuelle Fehler in der Konturschätzung haben keine Rückwirkungen auf den eigentlichen Filterprozess. Die nachträgliche Konturschätzung verbessert die Güte der Positionsschätzung des Filters, verhindert aber erhöhte normalisierte Fehlerquadrat-Werte während der Konturpunktsprünge nicht. Diese sind durch den ungünstigen Aspektwinkel während des Abbiegevorganges und das einfache, aber effiziente Objektmodell zu erklären.

Die neuartige Fusion objekt- und gitterbasierter Darstellungsformen ermöglicht eine Halbierung der Detektionslatenz. Hierbei werden Geschwindigkeitsinformationen bisher detektierter Objekthypothesen in einer gitterbasierten Darstellung gespeichert und neue Objekthypothesen mit diesen zusätzlichen Informationen initialisiert. Statt wie bisher nach 4 Zyklen (240ms) werden Objekthypothesen schon nach 2 Zyklen (120ms) initialisiert. Von dieser verbesserten Initialisierung profitieren 8,16 % aller neu initialisierten Objekthypothesen.

Das vorgestellte Verfahren arbeitet trotz des aufwändigeren Multi-Modell-Filters effizi-

ent und unterbietet die Anforderungen an die Echtzeitfähigkeit (Berechnung innerhalb von 60ms) deutlich. Im Mittel benötigt das Verfahren auf Standard-PC-Komponenten $1ms$ und unterbietet die Anforderung damit.

6 Zusammenfassung und Ausblick

Die Unfallforschung belegt, dass urbane Kreuzungsbereiche einen Unfallschwerpunkt bilden (siehe Abschnitt 1.1). Der Bedarf an Fahrerassistenzsystemen für urbane Kreuzungsbereiche wächst daher und wird in den nächsten Jahren weiter zunehmen. Gerade Fahrerassistenzsysteme mit maschineller Wahrnehmung, die im Gegensatz z. B. zu passiven Sicherheitssystemen die Möglichkeit besitzen, kritische Fahrsituationen bereits im Vorfeld zu vermeiden, sind Gegenstand aktueller Forschungsaktivitäten. Im Bereich der maschinellen Wahrnehmung haben sich in den letzten Jahren vor allem hybride Umfeldmodelle, bestehend aus der Fusion von graphen-, objekt- und gitterbasierten Umfeldmodellen, etabliert. In dieser Arbeit wurde eine objektbasierte Umfeldwahrnehmung im Kontext hybrider Umfeldmodelle mittels eines seriennahen Laserscanners realisiert. Die zentralen Schlussfolgerungen werden in Abbildung 6.1 und im Folgenden zusammengefasst:

Für die Algorithmen-Entwicklung wurde ein Konzept vorgeschlagen, das eine Referenzierung der Algorithmen von den ersten modellbasierten Untersuchungen bis zur Implementierung im Fahrzeug ermöglicht. Für die Simulationsszenarien werden die wahren Trajektorien als Referenz verwendet, für die realen Szenarien werden die relevanten Objekte auf dem Prüfgelände mittels eines satellitengestützten Koppelnavigationssystems referenziert. Ein belastbarer Vergleich von verschiedenen Algorithmen macht darüber hinaus objektive und reproduzierbare Gütekriterien notwendig, insbesondere das Einschwingverhalten der Algorithmen wird in den bisherigen Tracking-Kriterien nur unzureichend bewertet. Daher werden die bisherigen Kriterien um aus der Steuerungs- und Regelungstechnik bekannte und bewährte Kriterien zur Bewertung von Anregel-, Ausregel-, und Totzeit erweitert.

Um der erhöhten Wahrscheinlichkeit querdynamischer Manöver in Kreuzungsbereichen gerecht zu werden, wird ein Interacting-Multi-Model Filter mit drei Dynamikmodellen ('Linksabbiegen', 'Rechtsabbiegen' und 'Geradeaus Fahren') vorgeschlagen. Das verwendete Interacting-Multi-Model-Filter verlangt eine A-Priori-Bestimmung der Übergangswahrscheinlichkeiten zwischen den verschiedenen Dynamikmodellen. Im Kreuzungsbereich ist jedoch eine situationsabhängige Anpassung dieser Wahrscheinlichkeiten individuell für jede Objekthypothese notwendig. Hierfür wird mit dem Active-Interacting-Multi-Model Filter (AIMM)

eine neuartige Low-Level-Fusion von graphen- und objektbasierten Umfeldbeschreibungen zur situationsabhängigen Anpassung der zusätzlichen Design-Parameter vorgeschlagen. Das neuartige Verfahren stellt eine strukturelle Erweiterung des aus der Literatur bekannten Interacting-Multi-Model Filters dar. Die situationsabhängige Parameteradaption des Active-Interacting-Multi-Model Filters führt zu einer Minimierung der Zustandsunsicherheit, einer Verbesserung der Filterkonsistenz und einer früheren Manövererkennung. Für das Verfahren werden eine fahrstreifengenaue Ortung des Ego-Fahrzeuges und ein fahrstreifengenaues, graphenbasiertes Umfeldmodell vorausgesetzt. Des Weiteren wird angenommen, dass sich die Objekthypothesen konform zu den Regeln der Straßenverkehrsordnung verhalten.

Zur Minimierung der Detektionslatenz bei der Initialisierung von Objekthypothesen aus Laserscannerdaten wird eine neuartige Low-Level-Fusion von objekt- mit gitterbasierten Umfeldbeschreibungen vorgeschlagen. Hierbei werden die Geschwindigkeiten aller bisher detektierten Objekthypothesen in einer gitterbasierten Geschwindigkeitshistorie akkumuliert. Wird nun eine Objekthypothese neu initialisiert, so werden die an der betreffenden Stelle gespeicherten Geschwindigkeitsinformationen als zusätzliche Informationsquelle verwendet. Dieses Verfahren beschleunigt bei ca. 8% aller Objekthypothesen die Initialisierung, es setzt hierbei voraus, dass sich Objekthypothesen ähnlich verhalten wie zuvor detektierte Objekthypothesen. Auf Grund der Organisation des Straßenverkehrs in richtungsgebundene Fahrstreifen ist diese Forderung in der Regel erfüllt.

Ein Beitrag dieser Arbeit liegt in der Vorstellung von Algorithmen zur Nutzung der zusätzlichen Informationen eines hybriden Umfeldmodells. Hierfür werden neuartige Low-Level-Fusionen zwischen graphen- und objekt- sowie zwischen gitter- und objektbasierten Umfeldmodellen vorgeschlagen. Die Informationen aus dem graphenbasierten Umfeldmodell werden hierbei zur allgemeingültigen Anpassung der zusätzlichen Design-Parameter des Multi-Modell-Filters verwendet. Die Informationen aus dem gitterbasierten Umfeldmodell werden zur schnelleren Initialisierung der Objekthypothesen aus Laserscannerdaten verwendet.

Grenzen und daraus abgeleiteter weiterer Forschungsbedarf

- Das vorgestellte System setzt eine globale, fahrstreifengenaue Ortung voraus. Die Performance des in diesem Lösungsansatz verwendeten Koppelnavigationssystems ist im urbanen Umfeld jedoch unter Umständen stark eingeschränkt. Die Bebauung hat an den in der praktischen Evaluierung der Algorithmen genutzten Testkreuzungen einen Satellitenempfang zugelassen. Auf Grund z. B. von Abschattungen oder Mehrwegeausbreitung ist jedoch eine Störung oder ein Verlust des Empfanges möglich. Daher

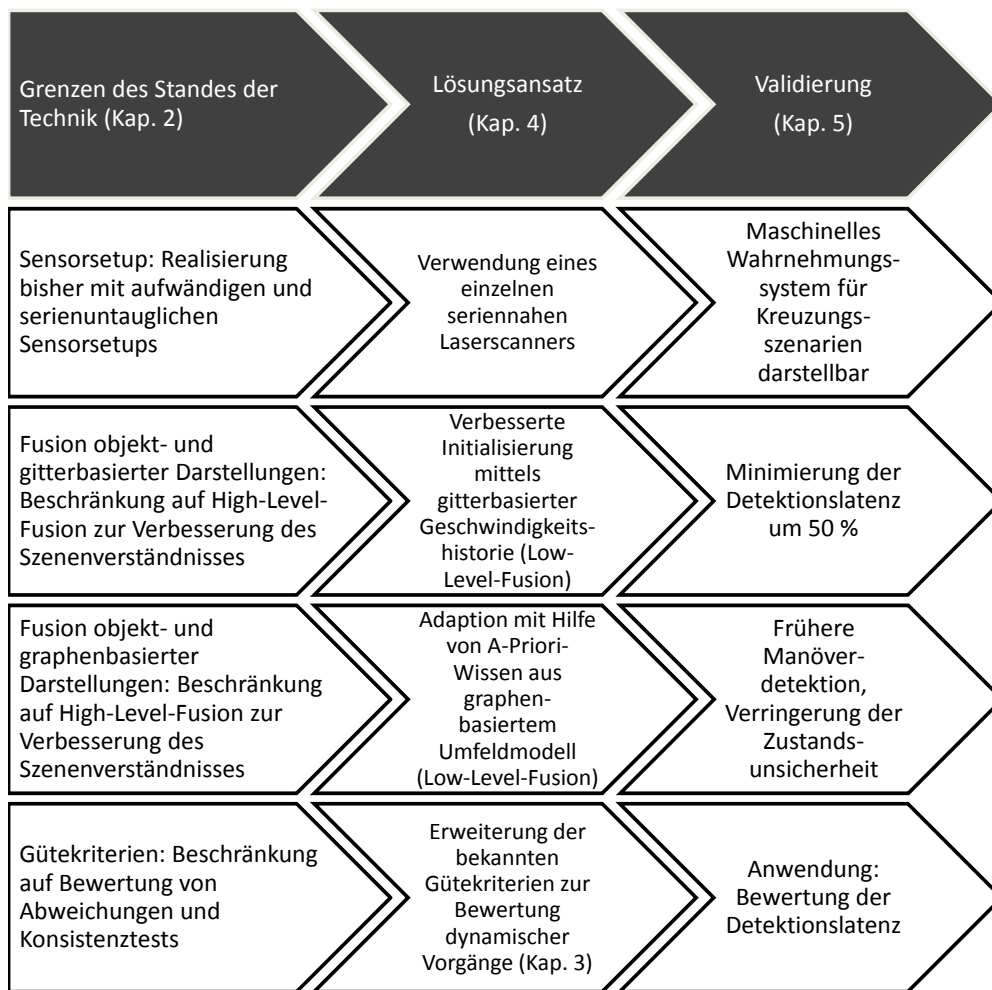


Bild 6.1: Schlussfolgerung dieser Arbeit.

besteht bezüglich einer satellitenunabhängigeren Ortungslösung für das urbane Umfeld weiterer Forschungsbedarf. Eine Verbesserung der Ortung könnte z. B. durch engere Verknüpfung von Informationen aus den Sensordaten (Fahrspurmarkierungen, Landmarken etc.) und der Ortung erzielt werden.

- Die Verwendung von Bewertungsalgorithmen und Gütekriterien setzt eine geeignete Referenzsensorik voraus. Für komplexe Umfeldmodelle, die bewegliche Objekte und stationäre Randbebauung abbilden, ist zur vollständigen Bewertung eine Referenzierung von kompletten Szenarien notwendig. Dies ist nach aktuellem Stand der Technik bisher nicht möglich, daher besteht ein Forschungsbedarf bezüglich der vollständigen Referenzierung urbaner Szenarien. Diese Arbeit beschränkt sich darauf, die relevanten Objekte mittels satellitengestützter Koppelnavigationssysteme zu referenzieren. Pro-

blematisch ist bei dieser Vorgehensweise jedoch die Satellitenabhängigkeit der Referenzsensorik. Eine Referenzierung ist damit nur unter Einschränkungen, z. B. freiem Himmel auf dem Prüfgelände, belastbar. Für urbane Szenarien sind die aktuell verfügbaren Systeme, je nach Situation und Satellitenempfang, kritisch zu hinterfragen oder sogar ungeeignet. Daher besteht bezüglich der belastbaren Referenzierung von Objekten im urbanen Umfeld Forschungsbedarf.

- Das vorgestellte Modell ist für einen das Fahrzeugvorfeld beobachtenden Sensor ausgelegt. Bezüglich der Erweiterung auf eine 360° Rundumsicht durch die Fusion mehrerer Sensoren besteht weiterer Forschungsbedarf.
- Bisher nutzen die Algorithmen für die Berechnung der Abbiegewahrscheinlichkeiten an den Kanten und Knoten gespeicherte Statistiken aus Verkehrszählungen. Für die Initialisierung aus der Geschwindigkeitshistorie werden durch die Sensorik gesammelte Informationen genutzt. Für beide Ansätze ist eine Erweiterung um zusätzliche dynamische Informationen, wie Extended Floating Car Data, erstrebenswert.
- Unvorhergesehene Manöver (Objekt verhält sich nicht konform bezüglich der Fahrstreifenmarkierungen, z. B. beim U-Turn) werden beim vorgestellten Active-Interacting-Multi-Model-Filter mit einer Verzögerung erkannt. Je nach Applikation ist hier eventuell eine inverse Implementierung sinnvoll: So könnte man bei einer Objekthypothese, die sich auf einem expliziten Linksabbiege-Fahrstreifen befindet, bei der Wahl der Übergangsmatrizen mit einer hohen Wahrscheinlichkeit von einer Geradeaus-Fahrt oder einem Rechtsabbiegen (also den unerwarteten Manövern) ausgehen. Dies ermöglicht ein frühes Erkennen unerwarteter (und damit potentiell gefährlicher Manöver) und ein späteres Erkennen der erwarteten Manöver (die auch vom Fahrer erwartet werden und die er damit eher selbst beherrscht). Daher besteht bezüglich der applikationsabhängigen Adaption der Übergangsmatrix ebenfalls Forschungsbedarf.

Literatur

- [Com 2010] *Towards a European road safety area: policy orientations on road safety 2011-2020*. European Commision, 2010
- [INT 2011] *Deliverable D8.2 – Test and Evaluation Results*. INTERSAFE-2, 2011
- [Baig u. a. 2009] BAIG, Q. ; VU, T.-D. ; AYCARD, O.: Online Localization and Mapping with Moving Objects Detection in Dynamic Outdoor Environments. In: *IEEE International Conference on Intelligent Computer Communication and Processing*. Cluj-Napoca, 2009, S. 401–408
- [Bar-Shalom u. Li 1993] BAR-SHALOM, Y. ; LI, X.-R.: *Estimation and tracking – Principles, techniques, and software*. Artech House, 1993
- [Bar-Shalom u. a. 2001] BAR-SHALOM, Y. ; LI, X.-R. ; KIRUBARAJAN, T.: *Estimation with Applications To Tracking and Navigation*. Wiley-Interscience, 2001
- [Bar-Shalom u. a. 2011] BAR-SHALOM, Y. ; WILLET, P.-K. ; TIAN, X.: *Tracking and Data Fusion: A Handbook of Algorithms*. 2011
- [Blackman 2004] BLACKMAN, S.: Multiple Hypothesis Tracking For Multiple Target Tracking. In: *IEEE Aerospace and Electronic Systems Magazine* 19 (2004), S. 5–18
- [Boehlau u. a. 2009] BOEHLAU, C. ; LICHTER, B. ; OTTENHUES, T.: New Concept of a Compact Lidar Scanner for ACC and Safety Applications. In: *SAE International Vehicle Sensors and Actuators*. Detroit, 2009
- [Bouzouraa u. Hofmann 2010] BOUZOURAA, M. E. ; HOFMANN, U.: Fusion of Occupancy Grid Mapping and Model Based Object Tracking for Driver Assistance Systems using Laser and Radar Sensors. In: *IEEE Intelligent Vehicles Symposium*. San Diego, 2010, S. 294–300
- [Bouzouraa u. Hofmann 2011] BOUZOURAA, M. E. ; HOFMANN, U.: Fusion kartenbasierter Umfeldwahrnehmung mit modellbasierter Objektverfolgung für Fahrerassistenzsysteme. In: MAURER, M. (Hrsg.) ; DIETMAYER, K. (Hrsg.) ; FÄRBER, B. (Hrsg.) ; STILLER, C. (Hrsg.) ; WINNER, H. (Hrsg.): *7. Workshop Fahrerassistenzsysteme*. 2011, S. 115–123
- [Brahmi 2013] BRAHMI, M.: Reference systems for environmental perception. In: MAURER, M. (Hrsg.) ; WINNER, H. (Hrsg.): *Automotive Systems Engineering*. Springer Verlag, 2013
- [Burlet u. a. 2006] BURLET, J. ; AYCARD, O. ; SPALANZANI, A. ; LAUGIER, C.: Pedestrian Tracking in car parks: an Adaptive Interacting Multiple Models based Filtering Method. In: *IEEE International Conference on Intelligent Transportation Systems*. Toronto, 2006, S. 462–467

- [Burlet u. a. 2008] BURLET, J. ; VU, T.-D. ; AYCARD, O.: Grid-based Localization and Online Mapping with Moving Object Detection and Tracking: New Results. In: *IEEE Intelligent Vehicles Symposium*. Eindhoven, 2008, S. 684–689
- [Canas u. Matellan 2006] CANAS, J. M. ; MATELLAN, V.: Dynamic Gridmaps: Comparing Building Techniques. In: *Mathware and Soft Computing* 13 (2006), S. 5–22
- [Darms 2007] DARMS, M.: *Eine Basis-Systemarchitektur zur Sensordatenfusion von Umfeldsensoren für Fahrerassistenzsysteme*, Technische Universität Darmstadt, Diss., 2007
- [Darms 2008] DARMS, M.: Vehicle Detection and Tracking for the Urban Grand Challenge. In: *AAET – Automatisierungs-, Assistenz- und eingebettete Systeme für Transportmittel*. Braunschweig, 2008, S. 260–277
- [Dietmayer u. a. 2001] DIETMAYER, K. ; SPARBERT, J. ; STRELLER, D.: A System Architecture for the Detection and Modeling of Dynamic Traffic Scenes. In: *IEEE Conference on Intelligent Transportation Systems*. Sydney, 2001
- [Doth 2009] DOTH, Sebastian: *Objektdatenbildung aus Messdaten und Anbindung an eine Sensordatenfusion für einen LIDAR-Sensor*, Technische Universität Ilmenau, Diplomarbeit, 2009
- [Dyckmanns u. a. 2011a] DYCKMANNS, H. ; MATTHAEI, R. ; MAURER, M. ; LICHTÉ, B.: Object Tracking in Urban Intersections: Active Interacting Multi Model Filter with Handling of Uncertainties of Map Matching. In: *International Conference of Information Fusion*. Chicago, 2011, S. 1110–1117
- [Dyckmanns u. a. 2011b] DYCKMANNS, H. ; MATTHAEI, R. ; MAURER, M. ; LICHTÉ, B. ; EFFERTZ, J. ; STUEKER, D.: Object tracking in urban intersections based on active use of a priori knowledge: Active interacting multi model filter. In: *IEEE Intelligent Vehicles Symposium*. Baden-Baden, 2011, S. 625–630
- [Dyckmanns u. a. 2011c] DYCKMANNS, H. ; MATTHAEI, R. ; MAURER, M. ; LICHTÉ, B. ; EFFERTZ, J. ; STUEKER, D.: Tracking und Konturschätzung in urbaner Umgebung auf Basis von Laserdaten. In: *AAET – Automatisierungs-, Assistenz- und eingebettete Systeme für Transportmittel*. Braunschweig, 2011, S. 370–390
- [Effertz 2008] EFFERTZ, J.: Tracking und Datenfusion im urbanen Fahrzeugumfeld. In: *AAET – Automatisierungs-, Assistenz- und eingebettete Systeme für Transportmittel*. Braunschweig, 2008, S. 182–197
- [Effertz 2009] EFFERTZ, J.: *Autonome Fahrzeugführung in urbaner Umgebung durch Kombination objekt- und kartenbasierter Umfeldmodelle*, Technische Universität Braunschweig, Diss., 2009
- [Fürstenberg u. Dietmayer 2004] FÜRSTENBERG, K. ; DIETMAYER, K.: Fahrzeugumfelderfassung mit mehrzeiligen Laserscannern. In: *Technisches Messen* 71 (2004), S. 164–172

- [Hautaniemi u. Saarinen 2001] HAUTANIEMI, S. K. ; SAARINEN, J. P.: Multitarget tracking with the IMM and Bayesian networks: Empirical studies. In: *Society of Photo-Optical Instrumentation Engineers Conference Series* 4385 (2001), S. 47–57
- [Hoffmann 2007] HOFFMANN, C.: *Fahrzeugdetektion durch Fusion monoskopischer Video-merkmale*, Universität Karlsruhe, Diss., 2007
- [Homeier u. Wolf 2011] HOMEIER, K. ; WOLF, L.: RoadGraph: High level sensor data fusion between objects and street network. In: *IEEE Conference on Intelligent Transportation Systems*. Washington, 2011, S. 1380–1385
- [Isard u. Blake 1998] ISARD, M. ; BLAKE, A.: Condensation – conditional density propagation for visual tracking. In: *International Journal of Computer Vision* 29 (1998), S. 5–28
- [Kalman 1960] KALMAN, R. E.: A New Approach to Linear Filtering and Prediction Problems. In: *Transactions of the ASME – Journal of Basic Engineering* 82 (1960), S. 35–45
- [Kapp 2007] KAPP, A.: *Ein Beitrag zur Verbesserung und Erweiterung der Lidar-Signalverarbeitung für Fahrzeuge*, Universität Karlsruhe, Diss., 2007
- [Karlsson 2002] KARLSSON, R.: *Simulation Based Methods for Target Tracking*, Universität Linköping, Diss., 2002
- [Ke u. a. 2000] KE, C. C. ; HERRERO, J. G. ; LLINAS, J.: Comparative Analysis of Alternative Ground Target Tracking Techniques . In: *International Conference on Information Fusion*. Buffalo, 2000, S. 3–10
- [Klose 2008] KLOSE, F.: *Sensorfusion von flächigen Umfelddaten anhand von Belegungskarten*, Technische Universität Braunschweig, Diplomarbeit, 2008
- [Kämpchen 2007] KÄMPCHEN, N.: *Feature-Level Fusion of Laser Scanner and Video Data for Advanced Driver Assistance Systems*, Universität Ulm, Diss., 2007
- [Kämpchen u. a. 2004] KÄMPCHEN, N. ; WEISS, K. ; SCHÄFER, M. ; DIETMAYER, K. C. J.: IMM Object Tracking for High Dynamic Driving Maneuvers. In: *IEEE Intelligent Vehicles Symposium*. Parma, 2004, S. 825–830
- [Knaup u. Homeier 2010] KNAUP, J. ; HOMEIER, K.: RoadGraph - Graph based environmental modelling and function independent situation analysis for driver assistance systems. In: *IEEE Conference on Intelligent Transportation Systems*. Funchal, 2010, S. 428–432
- [Knaup u. a. 2009] KNAUP, J. ; MEINECKE, M.-M. ; OBOJSKI, M. A. ; AHRHOLDT, M. ; GRUBB, G. ; PURSCHWITZ, A. ; HOPSTOCK, M.: How to Support Drivers in Intersection-related Scenarios – Functions of INTERSAFE-2 Demonstrator Vehicles. In: *IEEE International Conference on Intelligent Computer Communication and Processing*. Cluj-Napoca, 2009, S. 387–392
- [Leonard u. a. 2008] LEONARD, J. ; HOW, J. ; TELLER, S. ; BERGER, M. ; CAMPBELL, S. ; FIORE, G. ; FLETCHER, L. ; FRAZZOLI, E. ; HUANG, A. ; KARAMAN, S. ; KOCH, O. ; KUWATA, Y. ; MOORE, D. ; OLSON, E. ; PETERS, S. ; TEO, J. ; TRUAX, R. ; WALTER, M.:

- A Perception-Driven Autonomous Urban Vehicle. In: *Journal of Field Robotics* (2008), S. 1–48
- [Lindl 2008] LINDL, R.: *Tracking von Verkehrsteilnehmern im Kontext von Multisensorsystemen*, Technische Universität München, Diss., 2008
- [Lunze 2006] LUNZE, J.: *Regelungstechnik 2*. Springer Verlag, 2006
- [Lutz u. Wendt 2005] LUTZ, H. ; WENDT, W.: *Taschenbuch der Regelungstechnik*. Harri Deutsch, 2005
- [Matthaei u. a. 2011a] MATTHAEI, R. ; DYCKMANN, H. ; MAURER, M. ; EFFERTZ, J. ; STUEKER, D.: Segmentierung von Laserdaten in urbaner Umgebung unter Nutzung von Kontur- und Geschwindigkeitsdaten. In: *AAET – Automatisierungssysteme, Assistenzsysteme und eingebettete Systeme für Transportmittel*. Braunschweig, 2011, S. 355–369
- [Matthaei u. a. 2011b] MATTHAEI, R. ; DYCKMANN, H. ; MAURER, M. ; LICHT, B.: Motion Classification for Cross Traffic in Urban Environments Using Laser and Radar. In: *International Conference of Information Fusion*. Chicago, 2011, S. 1600–1607
- [Matthaei u. a. 2011c] MATTHAEI, R. ; DYCKMANN, H. ; MAURER, M. ; LICHT, B. ; EFFERTZ, J. ; STUEKER, D.: Consistency-based motion classification for laser sensors dealing with cross traffic in urban environments. In: *IEEE Intelligent Vehicles Symposium*. Baden-Baden, 2011, S. 1136–1141
- [Meitinger 2008] MEITINGER, K.-H.: *Top-Down-Entwicklung von Aktiven Sicherheitssystemen für Kreuzungen*, Technische Universität München, Diss., 2008
- [Mählich 2009] MÄHLICH, M.: *Filtersynthese zur simultanen Minimierung von Existenz-, Assoziations- und Zustandsunsicherheiten in der Fahrzeugumfelderfassung mit heterogenen Sensordaten*, Universität Ulm, Diss., 2009
- [Musicki u. a. 2004] MUSICKI, D. ; SUVOROVA, S. ; CHALLA, S.: Multi Target Tracking of Ground Targets in Clutter with LMIPDA-IMM. In: *International Conference on Information Fusion*. Stockholm, 2004, S. 1104–1110
- [Ohl u. a. 2011] OHL, S. ; MATTHAEI, R. ; MAURER, M. ; MÜLLER, M.: Softwarearchitektur der gitterbasierten Sensordatenfusion des Projekts Stadtpilot. In: *AAET – Automatisierungssysteme, Assistenzsysteme und eingebettete Systeme für Transportmittel*. Braunschweig, 2011, S. 280–297
- [Ohl u. Maurer 2011a] OHL, S. ; MAURER, M.: A Contour Classifying Kalman Filter Based On Evidence Theory. In: *IEEE International Conference on Intelligent Transportation Systems*. Washington, 2011, S. 1392–1397
- [Ohl u. Maurer 2011b] OHL, S. ; MAURER, M.: Ein Kontur schätzendes Kalmanfilter mithilfe der Evidenztheorie. In: MAURER, M. (Hrsg.) ; DIETMAYER, K. (Hrsg.) ; FÄRBER, B. (Hrsg.) ; STILLER, C. (Hrsg.) ; WINNER, H. (Hrsg.): *7. Workshop Fahrerassistenzsysteme*. 2011, S. 83–94

- [Petrovskaya u. Thrun 2008] PETROVSKAYA, A. ; THRUN, S.: Model Based Vehicle Tracking for Autonomous Driving in Urban Environments. In: *Proceedings of Robotics: Science and Systems IV*. Zürich, 2008
- [Rauskolb u. a. 2008] RAUSKOLB, F. W. ; BERGER, K. ; LIPSKI, C. ; MAGNOR, M. ; CORNELSEN, K. ; EFFERTZ, J. ; FORM, T. ; GRAEFE, F. ; OHL, S. ; SCHUMACHER, W. ; WILLE, J.-M. ; HECKER, P. ; NOTHDURFT, T. ; DOERING, M. ; HOMEIER, K. ; MORGENROTH, J. ; WOLF, L. ; BASARKE, C. ; BERGER, C. ; GÜLKE, T. ; KLOSE, F. ; RUMPE, B.: Caroline: An Autonomously Driving Vehicle for Urban Environments. In: *Journal of Field Robotics – Special Issue on the 2007 DARPA Urban Challenge* 25 (2008), S. 674–724
- [Reif 2009] REIF, K.: *Automobilelektronik*. Springer Verlag, 2009
- [Ristic u. a. 2004] RISTIC, B. ; ARULAMPALAM, S. ; GORDON, N.: *Beyond the Kalman Filter: Particle Filters for Tracking Applications*. Artech House, 2004
- [Roessler 2010] ROESSLER, B.: *Situation Analysis and Adaptive Risk Assessment for Advanced Intersection Safety Systems*, Universität Hamburg, Diss., 2010
- [Schäfer 2003] SCHÄFER, M.: *Hochdynamische Objektverfolgung mit Multi-Modell-Ansätzen*, Universität Ulm, Diplomarbeit, 2003
- [Schimmelpfennig u. Nackenhorst 1985] SCHIMMELPFENNIG, K.-H. ; NACKENHORST, U.: Bedeutung der Querbeschleunigung in der Verkehrsunfallrekonstruktion - Sicherheitsgrenze des Normalfahrers. In: *Verkehrsunfall und Fahrzeugtechnik* 23 (1985), S. 94–96
- [Schubert 2011] SCHUBERT, R.: *Integrated Bayesian Object and Situation Assessment for Lane Change Assistance*, Technische Universität Chemnitz, Diss., 2011
- [Schubert u. Wanielik 2009] SCHUBERT, R. ; WANIELIK, G.: Unifying Bayesian Networks and IMM Filtering for Improved Multiple Model Estimation. In: *International Conference on Information Fusion*. Seattle, 2009, S. 810–817
- [Schubert u. Wanielik 2011] SCHUBERT, R. ; WANIELIK, G.: Empirical Evaluation of a Unified Bayesian Object and Situation Assessment Approach for Lane Change Assistance. In: *IEEE International Conference on Intelligent Transportation Systems*. Washington, 2011, S. 1471–1476
- [Skutek 2006] SKUTEK, M.: *Ein PreCrash-System auf Basis multisensorieller Umgebungserfassung*, Technische Universität Chemnitz, Diss., 2006
- [Stahn 2010] STAHN, R.: *Modellbasierte Merkmalsplanung zur objektbezogenen laserscannerbasierten Navigation von Fahrzeugen*, Technische Universität Berlin, Diss., 2010
- [Stüker 2004] STÜKER, D.: *Heterogene Sensordatenfusion zur robusten Objektverfolgung im automobilen Straßenverkehr*, Universität Oldenburg, Diss., 2004
- [Wang 2004] WANG, C.-C.: *Simultaneous Localization, Mapping and Moving Object Tracking*, Universität Pittsburgh, Diss., 2004

- [Wang u. Thorpe 2002] WANG, C.-C. ; THORPE, C.: Simultaneous Localization and Mapping with Detection and Tracking of Moving Objects. In: *IEEE International Conference on Robotics and Automation*. Washington, 2002, S. 2918–2924
- [Weiß, K. 2006] WEISS, K.: *Interpretation von Fahrumgebungen für Fahrerassistenzsysteme*, Universität Rostock, Diss., 2006
- [Wille u. a. 2010] WILLE, J. M. ; SAUST, F. ; MAURER, M. ; NOTHDURFT, T. ; HECKER, P.: Projekthaus Stadtpilot: Autonomes Fahren auf dem Braunschweiger Stadtring. In: *Integrierte Sicherheit und Fahrerassistenzsysteme 26. VDI/VW-Gemeinschaftstagung 2104* (2010), S. 139–152
- [Zhang u. a. 2008] ZHANG, M. ; KNEDLIK, S. ; LOFFELD, O.: An Adaptive Road-Constrained IMM Estimator for Ground Target Tracking in GSM Networks. In: *International Conference on Information Fusion*. Köln, 2008, S. 1–8